T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY ARI KOLONİ ALGORİTMASI İLE KURAL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN GELİŞTİRİLMESİ

Hazırlayan
Fehim KÖYLÜ

Danışman
Prof. Dr. Derviş KARABOĞA

Doktora Tezi

Bu çalışma Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından FBD-12-3658 kodlu proje ile desteklenmiştir

Ağustos 2015
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Fehim KÖYLÜ

İmza:



YÖNERGEYE UYGUNLUK

"Yapay Arı Koloni Algoritması ile Kural Tabanlı Sınıflandırma Yöntemlerinin Geliştirilmesi" adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan
Fehim KÖYLÜ

Danışman
Prof. Dr. Derviş KARABOĞA

Bilgisayar Mühendisliği ABD Başkanı
Prof. Dr. Derviş KARABOĞA

Prof. Dr. Derviş KARABOĞA danışmanlığında **Fehim KÖYLÜ** tarafından hazırlanan **"Yapay Arı Koloni Algoritması ile Kural Tabanlı Sınıflandırma Yöntemlerinin Geliştirilmesi"** adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında **Doktora** tezi olarak kabul edilmiştir.

13/08/2015

JÜRİ :

Danışman	:	Prof. Dr. Derviş KARABOĞA
Üye	:	Doç. Dr. Halife KODAZ
Üye	:	Yrd. Doç. Dr. Mustafa Servet KIRAN
Üye	:	Yrd. Doç. Dr. Mustafa DANACI
Üye	:	Yrd. Doç. Dr. Mete ÇELİK

ONAY :

Bu tezin kabülü Enstitü Yönetim Kurulunun 25/08/2015 tarih ve 2015/35-30 sayılı kararı ile onaylanmıştır.

25 /08/2015

Prof. Dr. Kâzım KEŞLİOĞLU
Enstitü Müdürü

ÖNSÖZ / TEŞEKKÜR

"Yapay Arı Koloni Algoritması ile Veri Madenciliği Algoritmaları Geliştirilmesi" isimli tez çalışmasının seçiminde, yürütülmesinde, sonuçlandırılmasında ve sonuçlarının değerlendirilmesinde maddi-manevi bilgi, tecrübe, destek ve yardımlarını esirgemeyen çok değerli danışman hocam sayın Prof. Dr. Derviş KARABOĞA'ya teşekkür ederim.

Tez çalışmam boyunca yapılan çalışmalarda yardımlarını esirgemeyen, zaman ayıran ve bilgilerini paylaşan değerli hocam sayın Yrd. Doç. Dr. Mete ÇELİK'e teşekkür ederim.

Çalışmalarımı izleyerek yönlendiren, faydalı önerilerde bulunan tez izleme komitesinde görevli hocalarım sayın Prof. Dr. Veysel ASLANTAŞ'a ve sayın Yrd. Doç. Dr. Mete ÇELİK'e teşekkür ederim.

Tez savunma sınavıma katılarak değerli yorum ve önerilerde bulunan Selçuk Üniversitesi Bilgisayar Mühendisliği Bölümü öğretim üyeleri Doç. Dr. Halife KODAZ'a ve Yrd. Doç. Dr. Mustafa Servet KIRAN'a teşekkür ederim.

Yüksek lisans tezi sırasında bilgi, tecrübe ve yardımlarını esirgemeyen danışmanım Yrd. Doç. Dr. Mustafa DANACI'ya, doktora tez çalışmasının başında yaptığı yardımlarla katkı sağlayan Fırat Üniversitesi Bilgisayar Mühendisliği öğretim üyesi Doç. Dr. Bilal ALATAŞ'a, tez yazımı sırasındaki katkılarından dolayı kardeşim Arş. Gör. Ümran KÖYLÜ'ye, Erciyes Üniversitesi Fen Bilimleri Enstitüsü yönergeleri çerçevesinde tez yazımı için Latex sınıfını sağlayan Yrd. Doç. Dr. Mustafa YILDIRIM'a ve tez çalışmaları süresince ABC hakkında birikimlerini paylaşan Doç. Dr. Bahriye BAŞTÜRK AKAY'a teşekkür ederim. Önerilen çevrim-içi yöntemin test problemi deneylerinin yapılması esnasında iş istasyonu bilgisayarını kullandığım Harita Mühendisliği GIS/CBS Laboratuarının yöneticisi Prof. Dr. Erkan BEŞDOK'a, Mühendislik Fakültesi Dekanı Prof. Dr. Mustafa ALÇI'ya, Fen Bilimleri Enstitüsü Müdürü Prof. Dr. Kâzım KEŞLİOĞLU'na, müdür yardımcıları Doç. Dr. Mustafa TUTAK'a ve Prof. Dr. Abdurrahman AYVAZ'a teşekkür ederim.

Bu tez çalışmasında, FBD-12-3658 kodlu proje ile maddi destek veren Erciyes Üniversitesi, Bilimsel Araştırma Projeleri Birimi'ne, Mühendislik Fakültesi Dekanlığı'na ve Bilgisayar Mühendisliği Bölüm Başkanlığı'na teşekkür ederim.

Bugüne kadar bana verdikleri her türlü maddi ve manevi destek ile göstermiş oldukları sabır ve destekten dolayı babama, anneme, kardeşlerime ve ailemin diğer fertlerine en derin saygılarımı ve şükranlarımı sunarım. Ayrıca duaları ile her zaman destek olan dost ve büyüklerimin hepsine ayrı ayrı teşekkür ederim.

YAPAY ARI KOLONİ ALGORİTMASI İLE KURAL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN GELİŞTİRİLMESİ

Fehim KÖYLÜ
Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Doktora Tezi, Ağustos 2015
Danışman : Prof. Dr. Derviş KARABOĞA

ÖZET

Veri madenciliği, veri yığınları üzerinden anlamlı, ilginç, bilinmeyen bilginin farklı biçimlerde çıkartılması süreçlerine verilen genel isimdir. Kolay ve ekonomik biçimde toplanan ve çok büyük boyutlara ulaşan verinin işlenmesi gereken önemli bir ham maddeye dönüştüğü günümüz bilgi çağında, veri madenciliği; daha önce anlaşılamamış bir çok karmaşık problemin çözümlenmesi ve karar destek sistemlerinde kullanılmaktadır.

Klasik sezgisel algoritmalar, veriler arasında ortak özellikleri istatistik hesaplamalar (bilgi kazancı, entropi vb.) yardımıyla çıkarıp sınıflandırma kurallarını öğrenir. Verideki gürültü, çok boyutlu problem için yetersiz ve çözüm uzayına dengeli dağılmayan veri gibi nedenler kural öğrenmenin zorluklarıdır. Çok fazla ihtimalin olduğu sınırsız boyutlu karmaşık problemler için, en iyi çözüme kısa sürede yakınsayabilen stokastik meta-sezgisel araştırma yöntemleri literatürde kural öğrenimi için de sıklıkla kullanılmıştır. Bu algoritmalar, doğadaki kimyasal, fiziksel, biyolojik, genetik ve sürü davranışı gibi zeki sistemlerden esinlenmiştir. Yapay Arı Koloni algoritması, optimizasyon problemlerinde diğer meta-sezgisel algoritmalara göre daha yüksek performans sergilemektedir.

Bu tez çalışmasında, Yapay Arı Koloni Algoritması'na dayalı 3 farklı sınıflandırma öğrenme algoritması geliştirilmiştir. Geliştirilen algoritmalar, literatürde sıklıkla kullanılan test problemleri üzerinde test edilerek, sonuçları diğer kural öğrenme algoritmaları ile karşılaştırılmıştır. Geliştirilen algoritmalar, daha yüksek başarı oranlarına sahip probleme bağımlı olmadan genel kurallar keşfedebilmiştir.

Anahtar Kelimeler: Veri madenciliği, sınıflandırma, kural öğrenme, meta-sezgisel algoritmalar, Yapay Arı Koloni Algoritması (ABC).

DEVELOPING RULE BASED CLASSIFICATION APPROACHES USING ARTIFICIAL BEE COLONY ALGORITHM

Fehim KÖYLÜ
Erciyes University, Graduate School of Natural and Applied Sciences
Ph.D. Thesis, August 2015
Supervisor: Prof. Dr. Derviş KARABOĞA

ABSTRACT

Data mining is the process of extracting the meaningful, interesting, and unknown information from datasets. Nowadays, acquiring and storing the vast amount of data are cheap and easy. Information age gives the advantage of analysing and giving decisions for different complex problems which are not apprehensible before.

Classical heuristic algorithms extract the common features between data with the help of the statistical measurements (entropy, information gain, etc.) and build the rules. The noise, multi-dimensionality, insufficient data, and unbalanced observations decreases the performance of classical methods. Stochastic meta-heuristic search methods converge to the global solution of complex problems with infinite dimensions and probabilities in a short time. These algorithms were inspired by chemical, physical, biological, genetic, and swarm based intelligent behaivoral systems. In literature, meta-heuristic algorithms are used for rule learning. Artificial Bee Colony (ABC) algorithm is one of the swarm-based algorithms and it is applied on many optimization problems successfully.

This thesis proposes three different ABC based classification algorithms. Algorithms are evaulated on most popular test problems used in the literature. The results are compared with the state-of-the-art rule learning algorithms. The results show that the proposed algorithms can discover classification rules efficiently.

Keywords: Data Mining, classification, rule learning, meta-heuristic algorithms, artificial bee colony algorithm (ABC).

İÇİNDEKİLER

YAPAY ARI KOLONİ ALGORİTMASI İLE
KURAL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN GELİŞTİRİLMESİ

BİLİMSEL ETİĞE UYGUNLUK SAYFASI i

YÖNERGEYE UYGUNLUK SAYFASI ii

KABUL VE ONAY iii

ÖNSÖZ / TEŞEKKÜR iv

ÖZET vi

ABSTRACT vii

İÇİNDEKİLER viii

TABLOLAR LİSTESİ xii

ŞEKİLLER LİSTESİ xv

GİRİŞ **1**

1. BÖLÜM
VERİ MADENCİLİĞİ YÖNTEMLERİ

1.1. Veri Madenciliği **11**

1.1.1. Veri, Bilgi ve Bilgi Ürünü **11**

1.1.2. Veri Madenciliği ve Bilgi Keşfi için Kullanılan Bilim Dalları . . . **13**

1.1.3. Veri Madenciliği Problemleri ve Çözüm Araçları **17**

1.2. Veri Madenciliği Metodolojileri **19**

1.2.1. Bilgi Keşfi ve Veri Madenciliği (KDDM) Süreci **20**

1.2.2. CRISP-DM **20**

1.2.3. Cabena (1998) **22**

1.2.4. SEMMA **22**

1.3. Sınıflandırma Model ve Algoritmaları **22**

1.3.1. Sınıflandırma Hataları ve Değerlendirme Ölçütleri **25**

1.3.1.1. Hata matrisi ve Değerlendirme Ölçütleri 25
1.3.1.2. Entropi 27
1.3.1.3. Bilgi Kazancı 28
1.3.1.4. Gini İndisi 28
1.3.1.5. Kural değerlendirme 28
1.3.1.6. Meta-sezgisel Algoritmalarda Kullanılan Kalite Fonksiyonu 29
1.3.2. Karar Ağaçları 30
1.3.2.1. ID3 Algoritması 30
1.3.2.2. C4.5 Algoritması 31
1.3.2.3. CART Algoritması 32
1.3.3. Kural Tabanlı Klasik Sınıflandırma Sistemleri 32
1.3.3.1. CN2 Algoritması 34
1.3.3.2. RIPPER Algoritması 35
1.3.4. Meta-sezgisel Kural Öğrenme Algoritmaları 36
1.3.4.1. Pittsburgh Yaklaşımına Dayalı Kural Öğrenme Algoritmaları 37
1.3.4.2. Michigan Yaklaşımına Dayalı Tekrarlamalı Kural Öğrenme Algoritmaları 41
1.3.4.3. Michigan Yaklaşımına Dayalı İşbirlikçi Kural Öğrenme Algoritmaları 46

2. BÖLÜM
ABCMiner: İTERATİF YAKLAŞIM İLE ABC TABANLI SINIFLANDIRMA KURALLARI KEŞFİ ALGORİTMASI

2.1. Yapay Arı Koloni Algoritması (ABC) 54
2.2. ABCMiner Algoritması 59
2.2.1. ABCMiner Algoritmasında Kural Temsili 64
2.2.2. Kural Kümesi ve Sınıflandırma için Kullanımı 65
2.2.3. ABCMiner Algoritmasının Kontrol Parametreleri 66
2.2.4. Başlangıç Yiyecek Kaynaklarının Belirlenmesi 67
2.2.5. Yiyecek Kaynaklarının Kalitesinin Hesaplanması 67
2.2.6. Görevli ve Gözetleyici Arıların Yiyecek Kaynaklarına Gönderilmesi 67

2.2.7. Tükenen Kaynağın Terk Edilmesi ve Kaşif Arı Gönderilmesi . . . 68

2.2.8. En İyi Yiyecek Kaynağının Hafızaya Alınması 68

2.2.9. Keşfedilen Yiyecek Kaynağının Kurala Dönüştürülmesi 68

2.2.10. Kuralın Basitleştirilmesi 69

2.2.11. Yeni Kuralın Kural Kümesine Eklenmesi ve Eğitim Kümesinin Küçültülmesi 69

2.2.12. Temel Sınıfın Eklenmesi ve Kural Kümesinin Basitleştirilmesi . . 69

2.3. Deneyler 71

2.3.1. ABCMiner Algoritmasının Sınıflandırma Test Problemleri Üzerindeki Doğruluk Analizi 71

2.3.2. ABCMiner Algoritmasının Dengesiz Sınıf Dağılımlı Test Problemleri Üzerindeki Doğruluk Analizi 86

2.3.3. Değerlendirme 92

3. BÖLÜM
COABCMINER: İŞBİRLİĞİ YAKLAŞIMI İLE ABC TABANLI SINIFLANDIRMA KURALLARININ KEŞFİ ALGORİTMASI

3.1. CoABCMiner Algoritması 93

3.1.1. CoABCMiner Algoritmasında Kural Temsili 97

3.1.2. CoABCMiner Algoritma Kontrol Parametreleri 101

3.1.3. Başlangıç Yiyecek Kaynaklarının Değerlerinin Belirlenmesi . . . 101

3.1.4. Yiyecek Kaynaklarının Kalitesinin Hesaplanması 102

3.1.5. Yiyecek Kaynakları Arasında Ödüllü Yarışma 103

3.1.6. Sınıflandırma Kurallarının Yiyecek Kaynaklarından Çıkartılması 103

3.1.7. Aday Kuralların Sınıflandırma Doğruluk Başarısının Hesaplanması 104

3.1.8. Görevli ve Gözetleyici Arıların Yiyecek Kaynaklarına Gönderilmesi 104

3.1.9. En İyi Sınıflandırma Modelinin Hafızaya Alınması 105

3.1.10. Tükenen Kaynağın Terk Edilmesi ve Kaşif Arı Gönderilmesi . . 106

3.1.11. CoABCMiner Algoritmasının Keşfettiği Sınıflandırma Modeli: KuralSeti 107

3.2. Deneyler 107

3.2.1. CoABCMiner Algoritmasının Sınıflandırma Test Problemleri Üzerindeki Doğruluk Analizi . . . 107

3.2.2. CoABCMiner Algoritmasının Dengesiz Sınıf Dağılımlı Test Problemleri Üzerindeki Doğruluk Analizi . . . 123

3.2.3. CoABCMiner Algoritmasının Kontrol Parametre Hassasiyet Analizi . . . 132

3.2.4. Değerlendirme . . . 149

4. BÖLÜM
ONLINE-ABCMINER: ADAPTİF ÇEVRİM-İÇİ KURAL ÖĞRENME ALGORİTMASI

4.1. Online-ABCMiner Algoritması . . . 159

4.1.1. Online-ABCMiner Algoritmasının Kontrol Parametreleri . . . 164

4.2. Deneyler . . . 165

4.2.1. Online-ABCMiner Algoritmasının Büyük Veri Akışı Test Problemleri Üzerindeki Doğruluk Analizi . . . 165

4.2.2. Online-ABCMiner Algoritmasının Ani Kavram Sapması Karşısında İyileştirilmesi . . . 174

4.2.3. Değerlendirme . . . 183

5. BÖLÜM
TARTIŞMA, SONUÇ ve ÖNERİLER

5.1. Tartışma, Sonuç ve Öneriler . . . 184

KAYNAKLAR . . . 188

EKLER . . . 201

ÖZGEÇMİŞ . . . 297

TABLOLAR LİSTESİ

Tablo 1.1. Kural ile veri kümesi karşılaştırması. 29

Tablo 1.2. Veri kümesi indirgemesi ile tümevarımsal mantık programlamanın karşılaştırması. 48

Tablo 1.3. Mantık grameri örneği. 49

Tablo 1.4. Kural gösterimi için mantık grameri örneği. 50

Tablo 2.1. Algoritmaların kontrol parametrelerin deneylerde kullanılan değerleri [51, 60, 132]. 73

Tablo 2.2. Ortalama eğitim doğrulukları tablosu. 74

Tablo 2.3. Eğitim doğruluğu standart sapma değerleri tablosu. 74

Tablo 2.4. Ortalama test doğrulukları tablosu. 75

Tablo 2.5. Test doğruluğu standart sapma değerleri tablosu. 75

Tablo 2.6. Sınıflandırma modellerinin ortalama kural sayıları tablosu. 76

Tablo 2.7. Sınıflandırma modellerinin ortalama koşul sayıları tablosu. 77

Tablo 2.8. Algoritmaların ortalama çalışma süreleri tablosu. 78

Tablo 2.9. Algoritmaların test doğrulukları için orta degere dayalı karşıtlık değerleri tablosu (contrast estimation based on medians) [133]. 79

Tablo 2.10. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde eğitim doğrulukları tablosu. 88

Tablo 2.11. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde eğitim doğrulukları tablosu (devamı). 89

Tablo 2.12. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde test doğrulukları tablosu. 90

Tablo 2.13. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde test doğrulukları tablosu (devamı). 91

Tablo 3.1. CoABCMiner algoritmasının yeni komşu yiyecek kaynağı belirleme stratejisi. 105

Tablo 3.2. CoABCMiner kontrol parametrelerinin deneylerde kullanılan değerleri. 107

Tablo 3.3. Ortalama eğitim doğrulukları tablosu. 109

Tablo 3.4. Eğitim doğrulukları standart sapma değerleri. 109

Tablo 3.5. Ortalama test doğrulukları tablosu. 110

Tablo 3.6. Test doğrulukları standart sapma değerleri. 110

Tablo 3.7. En düşük ve en yüksek test doğrulukları tablosu. 112

Tablo 3.8. Sınıflandırma modellerinin sahip olduğu ortalama kural sayıları. . . . 119

Tablo 3.9. Algoritmalar tarafından öğrenilen en az ve en fazla kural sayıları. . . 120

Tablo 3.10. Sınıflandırma modellerinin sahip olduğu ortalama koşul sayıları. . . . 120

Tablo 3.11. Algoritmaların kural öğrenmeleri için geçen ortalama çalışma süreleri (msn.). 122

Tablo 3.12. Algoritmaların test doğrulukları için orta değere dayalı karşıtlık değerleri tablosu (contrast estimation based on medians) [133]. 123

Tablo 3.13. CoABCMiner kontrol algoritması ile diğer algoritmaların test doğruluk değerlerinin Friedman testi ile eşli analizi ve Bonferroni-Dunn, Holm, Hochberg, Hommel, Holland, Rom, Finner ve Li son düzeltme metotları ile güncellenmiş p değerleri ($\alpha = 0,05$) [133]. 126

Tablo 3.14. Genel karşılaştırma tablosu: Eğitim doğruluğu ve test doğruluğu ortalamaları, standart sapmaları, keşfedilen kural ve koşul ortalama sayıları, çalışma süreleri (msn.). 127

Tablo 3.15. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama eğitim doğrulukları. 128

Tablo 3.16. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama eğitim doğrulukları (devamı). 129

Tablo 3.17. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama test doğrulukları. 130

Tablo 3.18. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama test doğrulukları (devamı). 131

Tablo 3.19. Yeni kaşif arı ile temel kaşif arının Wilcoxon ilişkili iki örneklem testi ile analizi. 135

Tablo 3.20. MCN parametre değişimi ortalama test doğrulukları. 135

Tablo 3.21. MCN parametre değerlerinin test doğrulukları için Friedman testi. . 136

Tablo 3.22. $Limit$ parametre değişimi ortalama test doğrulukları. 138

Tablo 3.23. $Limit$ parametre değişimi test doğrulukları için Friedman testi. . . . 138

Tablo 3.24. KS parametre değişimi ortalama test doğrulukları. 147

Tablo 3.25. KS parametre değerlerinin test doğrulukları için Friedman testi. . . . 148

Tablo 3.26. $initOranı$ parametre deneyleri ortalama test doğrulukları. 148

Tablo 3.27. $initOranı$ parametre değişimi test doğrulukları için Friedman testi. . 148

Tablo 4.1. Online-ABCMiner algoritması kontrol parametreleri. 164

Tablo 4.2. Deneylerde kullanılan Online-ABCMiner parametre değerleri. 166

Tablo 4.3. Çevrim-içi kural öğrenme algoritmalarının veri akışları için ortaya koydukları sınıflandırma modellerinin kural sayıları ve doğruluk oranları. 167

Tablo 4.4. Online-ABCMiner algoritmasının tek ve yeni popülasyon stratejileri kullanılarak elde edilen doğruluk oranı ve kural sayısı istatistikleri. . 182

ŞEKİLLER LİSTESİ

Şekil 1.1. Veri madenciliği ve bilgi keşfi için kullanılan bilim dalları [20]. . . . 15

Şekil 1.2. Veri madenciliği problemi çözümü için geliştirilmiş CRISP-DM yaklaşımının aşamaları. 21

Şekil 1.3. Sınıflandırma problemi çözüm aşamaları. 23

Şekil 1.4. İkili sınıflandırma için hata matrisi. 26

Şekil 1.5. Meta-sezgisel kural öğrenme algoritmaları. 37

Şekil 1.6. LS-1 öğrenme yaklaşımı [134]. 39

Şekil 1.7. SAMUEL Algoritması Modülleri [76]. 51

Şekil 2.1. ABCMiner algoritması öğrenme süreci akış diyagramı. 63

Şekil 2.2. Lenf grafisi için ABCMiner'a ait örnek bir başlangıç çözüm popülasyonu. 66

Şekil 2.3. 10 kat çapraz doğrulama yöntemi. 72

Şekil 2.4. Lenf grafisi için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafiği. 79

Şekil 2.5. E.coli gen dizisi ve taşıtlar için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri. 80

Şekil 2.6. Soya fasülyesi ve hayvanat bahçesi için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri. 81

Şekil 2.7. Mantar ve monkun problemi 2 için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri. 82

Şekil 2.8. Süsen çiçeği ve diyabet için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri. 83

Şekil 2.9. Hepatit ve meme kanseri için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri. 84

Şekil 2.10. Wisconsin meme kanseri ve yeni tiroid için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri. 85

Şekil 3.1. CoABCMiner algoritması öğrenme süreci akış diyagramı. 97

Şekil 3.2. Lenf grafisi için CoABCMiner'a ait örnek bir başlangıç yiyecek kaynaklarının (kural) gösterimi. 100

Şekil 3.3. E.coli gen dizisi ve taşıtlar veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri. 113

Şekil 3.4. Soya fasülyesi ve hayvanat bahçesi veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri. 114

Şekil 3.5. Mantar ve monkun problemi 2 veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri. 115

Şekil 3.6. Süsen çiçeği ve diyabet veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri. 116

Şekil 3.7. Hepatit ve kanser veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri. 117

Şekil 3.8. Wisconsin meme kanseri ve yeni tiroid veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri. 118

Şekil 3.9. Lenf grafisi için eğitim ve test doğruluklarının kutu ve saçılım grafiği. 119

Şekil 3.10. CoABCMiner algoritmasında kullanılan yeni kaşif arı ve temel kaşif arı deneyleri eğitim doğrulukları grafiği. 133

Şekil 3.11. CoABCMiner algoritmasında kullanılan yeni kaşif arı ve temel kaşif arı deneyleri test doğrulukları grafiği. 134

Şekil 3.12. MCN parametre değişimi için ortalama eğitim doğrulukları grafiği. . 136

Şekil 3.13. MCN parametre değişimi için ortalama test doğrulukları grafiği. . . 137

Şekil 3.14. MCN parametre değişimi için ortalama kural sayısı grafiği. 139

Şekil 3.15. MCN parametre değişimi için kural başına öğrenilen ortalama koşul sayısı grafiği. 140

Şekil 3.16. $Limit$ parametre değişimi için ortalama eğitim doğruluklarının radar ağ grafiği. 141

Şekil 3.17. $Limit$ parametre değişimi için ortalama test doğruluklarının radar ağ grafiği. 141

Şekil 3.18. $Limit$ parametre değişimi için ortalama kural sayısı grafiği. 142

Şekil 3.19. $Limit$ parametre değişimi için kural başına öğrenilen ortalama koşul sayısı grafiği. 142

Şekil 3.20. KS parametre değişimi için ortalama eğitim doğruluklarının radar ağ grafiği. 143

Şekil 3.21. KS parametre değişimi için ortalama test doğruluklarının radar ağ grafiği. 143

Şekil 3.22. KS parametre değişimi için ortalama kural sayısı grafiği. 144

Şekil 3.23. KS parametre değişimi için kural başına öğrenilen ortalama koşul sayısı değişimi grafiği. 144

Şekil 3.24. $initOranı$ kontrol parametre değişimi için ortalama eğitim doğrulukları radar ağ grafiği. 145

Şekil 3.25. $initOranı$ parametre değişimi için test doğrulukları radar ağ grafiği. . 145

Şekil 3.26. $initOranı$ parametre değişimi için ortalama kural sayısı grafiği. . . . 146

Şekil 3.27. $initOranı$ parametre değişimi için kural başına öğrenilen ortalama koşul sayısı grafiği. 146

Şekil 4.1. Çevrim-içi sınıflandırma öğrenme algoritmaları. 154

Şekil 4.2. Çevrim-içi eğitimde kullanılan veri penceresi ve veri akışı. 160

Şekil 4.3. Online-ABCMiner çevrim-içi öğrenme süreci akış diyagramı. 161

Şekil 4.4. Agrawal ve Airlines veri akışları için doğruluk değişim grafiği. 169

Şekil 4.5. CovType ve Hyperplane veri akışları için doğruluk değişim grafiği. . 170

Şekil 4.6. Led ve Poker veri akışları için doğruluk değişim grafiği. 171

Şekil 4.7. Power ve RandomRBF veri akışları için doğruluk değişim grafiği. . . 172

Şekil 4.8. RandomTree ve Sea veri akışları için doğruluk değişim grafiği. 173

Şekil 4.9. Agrawal ve Airlines veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği. 177

Şekil 4.10. CovType ve Hyperplane veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği. 178

Şekil 4.11. Led ve Poker veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği. 179

Şekil 4.12. Power ve RandomRBF veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği. 180

Şekil 4.13. RandomTree ve Sea veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği. 181

GİRİŞ

İnsanoğlunun yaşamını sürdürebilmesi için her canlı gibi bazı temel ihtiyaçlara ihtiyacı vardır ve bunları temin etmesi gerekir. Diğer canlılar, bu ihtiyaçları ilkel biçimde karşılayacak özellikteki organlara ve sezgi kabiliyetine sahipken insan temel olarak beslenebilmek için avlanmak, hazırlamak ve pişirmek gibi yöntemler kullanmaktadır. Bunu yaparken insan hayal etmek, hafızayı kullanmak, düşünmek, anlamak ve mantıksal çıkarımlar yapmak gibi yeteneklerle donatılmış beynini ve zeka kabiliyetini kullanır. Böylece araştırma yapar, farklı yöntemler ve çözüm yolları dener, tecrübe edinir ve problemleri çözmek için bunlardan en uygun olanını belirleyip kullanır. Doğal kaynaklardan faydalanma ve ihtiyaçları karşılama biçimi, sürekli gelişme göstermiş, öncekinden daha hızlı, kolay ve ucuz olabilecek tasarımlar, teknikler, yöntemler, aletler ve cihazlar ortaya konulmaya çalışılmıştır. Elde edilen bu gelişmeler, defalarca yapılan deneylerden ve hassas hesaplamalardan sonra ulaşılan tecrübelerin birbirine eklenmesi ile ortaya çıkmaktadır. Herhangi bir bilimsel alanda çalışan uzmanlar, daha iyi çözümü elde edebilmek için sürekli yeni çalışmalar yaparak yeni bilgiler keşfetmeye çalışırlar. Böylece sistemlerin sebep-sonuç ilişkisi öğrenilir, problemlerin girdi ve çıktı parametreleri arasındaki bağıntılar ortaya konulur ve arzu edilen sistem cevabı için gerekli tasarımlar gerçekleştirilir [1, 2]. Günümüze kadar süregelen bilimin bu gelişme süreci, klasik veri analizi olarak adlandırılabilir. 18. yüzyılda, demir, kömür ve petrol madenleri yoğun biçimde kullanılmaya başlanmış ve böylece sanayi çağı başlamıştır [3]. İnsanlar ürün ve hizmetleri, daha kolay, ucuz ve hızlı yöntemlerle elde etmiştir. Elektrik, yarı iletken, bilgisayar ve internetin keşfi ile bilgi çağı ortaya çıkmıştır. Sanayi çağının getirdiği hız ile ivmelenen bilgi birikimi, günümüz bilgi çağında doruk noktasına ulaşmıştır. Dünyanın her hangi bir köşesinde kolayca toplanan veri, çok hızlı bir şekilde işlenip, ekonomik biçimde başka bir noktaya iletilebilir duruma gelmiştir. Dijital evren olarak adlandırılan bilişim sektörü ve zengin veri üreten teknolojik cihaz büyüklüğü hakkındaki IDC raporunda geçmişle karşılaştırılan günümüz rakamları

doğrultusunda gelecek dönem tahminleri verilmektedir. Bu rapora göre, 2020 yılında 4 milyar insanın internet kullanacağı, toplam 25 milyar nesnelerin interneti cihazının aktif biçimde internete bağlanacağı ve böylece sistemler üzerindeki toplam veri boyutunun 50 zettabayt (50 milyar terabayt) büyüklüğe ulaşacağı tahmin edilmektedir [4, 5].

Verinin elde edilmesi depolanması ve işlenmesi için hızlı, sağlam, kararlı ve etkin bir yapı sunan varlık-ilişki modeline dayalı veritabanları ilk kez 1976'da ortaya konulmuştur. İlişkisel veritabanı yönetim sistemleri, veride bütünlük, merkezi, esnek ve güvenli veri yönetimi gibi avantajlar getirmiştir [6–8]. İlişkisel veritabanı sistemlerindeki gelişmeler sonucu kayıt altına alınan veri sayısı 1980'lerden itibaren üstel bir artış göstermiştir. Bilgi işlem kapasitesindeki bu artış, çözümü karmaşık problemler için yeni çıkartımların elde edilmesinin yolunu açmıştır. Dolayısıyla petrol vb. madenler sanayi çağında ne kadar değerli bir ham madde ise veri de bilgi çağının ham maddesi olmuştur [7, 9]. Bununla birlikte devasa boyutlarda büyüklüğe ulaşan ve giderek artan bu veri yığınlarını işlemek ve böylece kullanışlı, verimli, değerli ve anlamlı özbilgiyi ortaya çıkartmak için yeni yöntemlere ihtiyaç duyulmuştur. Bu bilgi işlem sürecini ve analiz tekniklerini tanımlamak için 1990'ların başında veri madenciliği ve veritabanından bilgi keşfi kavramları ortaya çıkmıştır [10]. Bilgi keşfi ve veri madenciliği (knowledge discovery and data mining, KDDM); karmaşık problemlere ait girdi ile çıktı öznitelikleri arasındaki belirgin bağıntının, matematik, istatistik, bilgisayar yazılımı, makineli öğrenme, yapay zeka ve veritabanı gibi değişik bilimsel disiplinlerin bir arada kullanılması ile analiz edilmesi ve böylece ham veri yığınından, öz, anlamlı bilginin keşfedilmesi ve ortaya konulması işlemleri olarak tanımlanmaktadır. Günümüzde veri madenciliği; sosyal ağ analizi, toplumbilim, tıp, endüstri, pazarlama, ekonomi, mühendislik, astronomi, fizik, biyoenformatik ve meteoroloji gibi bir çok alanda kullanılmaktadır [9–11].

Literatür Özeti

Veri madenciliği, toplanan verinin analiz edilmesi ve anlamlı öz bilginin çıkartılması sürecidir [10]. Veri madenciliği bilim dalında yapılacak aşamaları standartlaştırmak amacıyla literatürde değişik metodolojiler ortaya konulmuştur [10, 12–14]. Analiz ve çıkarımlar yapılırken, istatistik, veritabanı sistemleri, makineli öğrenme ve örüntü tanıma yaklaşımları, yapay zeka ve hesaplama zekası meta-sezgisel yaklaşımlar olmak üzere

çok çeşitli bilim dalları bir arada kullanılır. İstatistik bilimi ve matematiksel işlemler, sözel ve sayısal biçimde kaydedilmiş verilerin özetlenmesi için yararlanılan en temel araçlardır [15]. Verilerin yapısal biçimde depolanması ve işlenmesi için veritabanı yönetim sistemleri kullanılmaktadır [8]. Makineli öğrenme ve örüntü tanıma yöntemleri, bir sistem davranışının ve özelliklerinin bilgisayar tarafından öğrenilmesi, kavranması süreci ile bilgi keşfi ve anlamlı model çıkarımı için gerekli yinelemeli yöntemleri ortaya koyar. Meta-sezgisel yaklaşımlar, çok olasılıklı karmaşık problemlerde yetersiz veri üzerinden etkin ve hızlı çözümler geliştirmek için kullanılır [16, 17].

Veri madenciliği araçlarının başarısı yapılan ön işlemlere ve verinin kalitesine bağlıdır. Veriler, kategorik, sıralı grup (ordinal), sürekli sayı veya tam sayı içeren bilgiler içerir. Kategorik veri, önceden tanımlanmış sınırlı sayıdaki kategori değerlerinden birini alabilir. Sıralı grup (ordinal) veri, küçük, orta, büyük gibi kendi arasında bir sıralamanın olduğu grup içindeki değerlerden birini alır. Sürekli sayı türündeki veri, öznitelik içinde gerçel sayı değerleri tutar. Tam sayı alabilen veri ise öznitelik değerinde sadece tam sayı değerleri barındırır. Veri toplama işlemindeki doğruluk, yapılacak analizi doğrudan etkileyecektir. Gürültülü, yanlış veya sınırlandırılmış hassasiyet ile ölçüm, sayısal türdeki veri için ortaya çıkabilecek hatalı veri toplama nedenlerindendir. Yanlış grup atama, değerinin harf eksikliği, tipografi hatası vb. biçimde hatalı girilmesi, kategorik veri için yapılabilecek veri kalitesini düşürecek hatalardandır. Veri kaydı sırasında eksik veri olması analizi zorlaştıracaktır. Örneğin veri toplama sensöründe ortaya çıkacak bir kopma ya da hatalı ölçüm verideki bütünlüğü bozan etkenlerdendir. Bazı sınıflara ait yeterli verinin olmaması, toplanan veri kümesinin dengesiz olmasına yol açar. Dolayısıyla çıkartılacak modelin kapsama alanı nadir olaylar için duyarsızlaşır, kalite ve doğruluğunu düşürücü etkiye sebep olur [18].

Veriden anlamlı bilgi keşfi, tahmin ve açıklayıcı olmak üzere iki farklı amacı hedefler. Yöntemlerin tahmin amacıyla kullanılması, toplanmış verinin analiz edilmesini ve sistemin tanımlanmasını gerektirir, daha sonra yeni durumların bilinmeyen değeri tahmin edilmeye çalışılır. Yöntemlerin özetleyici bilgi çıkarımı amacı ile kullanılması, veri kümesinin incelenmesi ve sade, öz ve anlamlı bilginin ortaya konulması ile sonuçlanır. Bu iki amaca yönelik veri madenciliği araçları, kümeleme, aykırılık tespiti, birliktelik kuralları (ilişki örüntüleri), regresyon analizi, sınıflandırma gibi farklı alt başlıklar altında

incelenmektedir. Kümeleme, aykırılık tespiti, birliktelik kuralları yaklaşımlarında veri kümesi içindeki kayıtlar arası ortak noktalar tahmin edilmeye çalışılırken, regresyon analizi ve sınıflandırma yaklaşımlarında, her bir veri için bağımlı özniteliğin değeri tahmin edilmeye çalışılır [15].

Birinci grup veri madenciliği yöntemi, kümeleme işlemleridir. Kümeleme yöntemleri, veri yığınının ortak özellikleri göz önüne alınarak verilerin aralarındaki benzerlikler doğrultusunda alt gruplara ayrıştırılması işlemidir. Bu tür problemlerde, verinin hangi sınıfa ait olduğunu belirten çıkış özniteliği bilinmediği için bağımsız öznitelik değerleri incelenir, örnekler arası ortak noktalar çeşitli indirgeme yöntemleri ile çıkartılmaya çalışılır. Kümeler ortaya konulduktan sonra gelecek her yeni örnek, öznitelik değerleri karşılaştırılarak en benzer gruba yerleştirilir.

İkinci grup veri madenciliği yöntemi, başka bir problem analizi için geliştirilmiş aykırılık tespit işlemleridir. Aykırılık tespiti yöntemleri, veri kümesinde ortalama dışına çıkan ve/veya genel eğilime aykırılık gösteren örneklerin tespit edilmesi için geliştirilmiştir. Diğer yöntemler için gürültü kabul edilebilecek uç veriler bu çözüm yönteminde aranan bilgi olarak ele alınmaktadır.

Üçüncü grup analiz yöntemi birliktelik kuralları (ilişki örüntüleri) tespit edilmesi işlemleridir. Bu yöntemler, kümeleme ve aykırılık tespitinde olduğu gibi, yine veriler arası ortak noktalar belirsiz olduğu problemlerde kullanılır. İlişki örüntüleri, öznitelikler arası sıklıkla birlikte geçen ortak özellikleri araştırır. İlişki örüntüleri keşfi için literatürde en temel algoritma Apriori algoritmasıdır [19].

Dördüncü gruptaki veri madenciliği analiz yöntemi regresyon işlemleridir. Regresyon yöntemleri, verinin analizi sonucunda sistemin davranışını gösteren ve değişkenler arasındaki ilişkiyi ifade eden matematiksel bir model çıkarmaya yönelik geliştirilmiştir. Matematiksel modelin ifade edilebilmesi için sisteme ait bağımsız giriş öznitelikleri ile bağımlı çıkış özniteliğinin değerlerinin kesin olarak bilinmesi gerekir. Sistemin çıkış değerleri sürekli sayısal türde değerler alır. Regresyon analizi sonucunda çıkış değerinin giriş özniteliklerine bağlı olarak hesaplandığı bir bağıntı çıkartılır.

Son grup veri madenciliği analiz yöntemi sınıflandırma işlemleridir. Sınıflandırma işlemi,

bir örneğin bağımsız öznitelik değerleri yardımıyla, bilinmeyen öznitelik değerinin önceden belirli kategorik değerlerden hangisi olacağının tahmin edilmesidir. Olayların, varlıkların daha kolay anlaşılması, daha sistematik biçimde ele alınabilmesi için günlük hayatta sıklıkla sınıflandırma işlemine ihtiyaç duyulur. Sınıflandırma yöntemlerinde, regresyon işleminde olduğu gibi aynı şekilde veri çiftlerine ihtiyaç duyulur. Regresyon analizinde bağımlı öznitelik değeri, sürekli sayısal değere sahipken, sınıflandırma probleminde ise ayrık, kategorik değer alır. Sınıflandırma işlemi için öncelikle probleme özgü bir sınıflandırıcı model öğrenilir. Bu model, daha sonra karşılaşılacak durumların sınıf değerinin tahmin edilmesinde kullanılır. Ortaya konulan sınıflandırma modelleri, öğrenme yaklaşımına göre matematiksel bağıntı, Bayes istatistik teoremi, karar destek makineleri, örnek tabanlı yöntemler, karar ağaçları, eğer-ise kuralları, yapay sinir ağı modelleri gibi çok farklı biçimde olabilmektedir. Sınıflandırma yaklaşımlarındaki ana hedef, öğrenilen modelin doğruluğunun olabildiğince yüksek olması ve sonraki tahmin işlemlerinin başarılı biçimde yapılmasıdır [10, 11, 15, 20].

Sınıflandırma problemi bilgisayar biliminde çok geniş bir uygulama sahasına sahiptir. Günümüzde ses, yüz, karakter, el yazısı, parmak izi vb. biyometrik tanımada, coğrafi, tıbbi, robotik görüntüleme sistemleri vb. görüntü işleme teknolojisinde, tıbbi tahlil sonuçları ile hastalık teşhisi, iş zekası yönetim sistemleri vb. karar destek sistemlerinde kullanılmaktadır. Herhangi bir çevre hakkında bilgisayarlı sınıflandırma yapabilmek için öncelikle yeterli bir ön verinin toplanması ve problem hakkında sebep-sonuç ilişkisinin keşfedilmesi, makineli öğrenme terimi ile ifade edilecek olursa denetimli öğrenim yapılması gerekir. Öğrenme işlemi tamamlandığında sınıflandırma modeli ya da sınıflandırıcı adı verilen sistem giriş-çıkış ağı ortaya konulur. Daha sonra karşılaşılacak bir verinin hangi kategoriye ait olacağı sınıflandırıcı ile tahmin edilir. Sınıflandırma modeli öğrenme yaklaşımları, bilgisayar biliminde bir sistem davranış ve özelliklerinin bilgisayar tarafından öğrenilmesi amacıyla geliştirilmiş teknik ve yöntemleri tanımlayan veri madenciliği bilim dalı altında incelenir. Bu teknikler, mevcut bir kavram veya sistem hakkında elde edilmiş sınırlı sayıdaki örnek veriyi kullanır, sistemi en yaklaşık biçimde modelleyecek hipotezleri ortaya koyar. Yöntemler, basit bir başlangıç hipotezi ile yola çıkar, giriş-çıkış arası bağıntıyı yineleyen adımlar ile sürekli geliştirir. Zaman ve işlem yükü maliyetlerini aşmadan, veri kümesini olabildiğince basit ve doğru şekilde

genelleyecek ve sistemi makul düzeyde karşılayacak modelin bulunması ile tamamlanır. Keşfedilen hipotezler, sistemi hiçbir zaman tam anlamıyla karşılayamaz. Sistem hakkında bütün olasılıkları içeren çok sayıda örnek toplanabilmesi hem ekonomik hem süre açışından mümkün olamadığından dolayı, sistem hakkında sadece yaklaşık bir model ortaya konulabilir. Eğitimden sonra sınıflandırıcı, test verileri ile sınanarak, bilinmeyen durumlar karşısında göstereceği başarı incelenir. Doğruluğu ve başarısı kanıtlanmış model, yeni verilerin sınıfını tahmin etmek için kullanılabilir [11, 15, 17, 18].

Makineli öğrenme yaklaşımlarında, çözüm uzayı üzerindeki optimum çözümü bulabilmek için yapılan araştırma çalışmasında, rastgele arama, aç gözlü yaklaşım veya diğer sezgisel metodolojilerin biri kullanılmaktadır. Birinci araştırma metodolojisi, rastgele ya da sistematik arama yaklaşımları, parametrelerin alabileceği değerlerin çok farklı kombinasyonunu deneme yanılma yöntemi ile deneyen kaba kuvvet (brute force) yaklaşımıdır. Arama uzayının her bir boyutunun alabileceği komşuluk değerlerini sırasıyla dener. İkinci tür sezgisel araştırma metodolojisi aç gözlü yaklaşımlardır. Rastgele yaklaşımdaki gibi her bir komşuluk değerini test etmez. Böylece daha az araştırma yapıp, sonuca yaklaşmaya çalışır. Gradyen (gradient), tepe tırmanma (hill-climbing) vb. yöntemler klasik aç gözlü yaklaşımlara örnek verilebilir. Aç gözlü yaklaşımlarda araştırma, başlama noktası rasgele seçildikten sonra daha iyi sonuç veren komşuluklar yönünde ilerletilir. Aç gözlü yaklaşımlar daha az işlem maliyeti ile yaklaşık çözüm bulma avantajına sahiptir. Ancak kullanılan ilerleme stratejisi doğrultusunda, en iyi çözüm yerine başlangıç noktasına bağlı olarak yerel bir çözüme takılma riski barındırır. Üçüncü grup araştırma metodoloji hem rastgele, hem de aç gözlü araştırmayı bir arada yapabilen yaklaşımlardır. Evrimsel algoritmalar ve sürü zekası algoritmaları gibi hesaplama zekası temelli algoritmalar ya da meta-sezgisel optimizasyon algoritmaları bu grupta incelenir. Bu tür algoritmalar, bölgesel çözüme takılma riskini gidermek ve çözüm uzayında farklı boyutlarda araştırmayı sürdürebilmek için rastgelelik içeren geçiş kuralları kullanarak çözümleri paralel bir şekilde geliştirmeye çalışır [15, 16, 18, 21].

Karar ağaçları ve eğer-ise kuralları ile yapılan sınıflandırıcılar, insanlar tarafından da anlaşılır olduğu için sınıflandırma modelleri arasında önemli bir yere sahiptir. Veri kümesinden karar ağacı indirgemesi için, adım adım çözümü geliştiren çeşitli klasik aç gözlü sezgisel algoritmalar geliştirilmiştir. Bu tür yöntemler, karar ağaçlarını kök

düğümünden dallara doğru ilerleyen biçimde geliştirir. Bilgi kazancı, Gini indisi vb. nitelik seçme ölçütleri yardımıyla, veri kümesi tekrarlı biçimde alt kümelere ayrıştırılır. Her bir alt kümedeki ortak öznitelik değeri doğrultusunda düğümde yer alacak dallandırma şartı belirlenir. ID3, C4.5 ve CART klasik karar ağacı algoritmalarıdır [15]. Kural bazlı sınıflandırıcılar, giriş-çıkış arasındaki bağıntıyı eğer-ise kuralları ile modeller. Karar ağaçları, kural bazlı sınıflandırıcılar ile benzerliklere sahip olduğu için eğer-ise kurallarına dönüştürülebilmektedir. Eğer-ise kurallarını veri kümesi üzerinden keşfedebilmek amacıyla C4.5Rules, CN2, AQ ve RIPPER gibi klasik algoritmalar geliştirilmiştir [135]. Bu algoritmalar, sınıflandırma modelini tanımlayan kural kümesindeki her bir kuralı ardışık biçimde keşfeder. Sırasıyla keşfedilen her bir kural tarafından kapsanan örnekler veri kümesinden çıkartılır. Kalan örnekler ile yeni bir kural araştırmaya çalışılır.

Aç gözlü yaklaşımların sahip olduğu yerel çözüme takılma probleminden dolayı, klasik kural öğrenme algoritmaları yerine literatürde meta-sezgisel algoritmalara dayalı araştırma yapabilen yeni hesaplama zekası temelli kural öğrenme algoritmaları geliştirilmiştir. Bu yöntemlerde, veride olabilecek gürültüye karşı daha kararlı, çözüm uzayının karmaşıklığı ile baş edebilecek biçimde az sayıdaki eğitim örneğini kullanarak genel ve doğruluğu yüksek kural tabanlı sınıflandırma modellerini hızlı biçimde ortaya koyabilmek amaçlanmıştır. Genetik algoritma (GA) [22], Karınca Koloni Algoritması (ACO) [23], Parçacık Sürü Optimizasyonu (PSO) [24], Diferansiyel Gelişim (DE) [25], Tabu Araştırma (TS) [26, 27], Isıl İşlem (SA) [28], Yapay Bağışıklık (AI) [29], Yapay Arı Koloni (ABC) [21] algoritması gibi algoritmalar, hızlı ve bölgesel çözümlere takılmadan küresel en iyi çözümü bulabilmek için geliştirilmiş evrimsel ve sürü zekası temelli meta-sezgisel algoritmalardır. Bu algoritmalar karmaşık ve gürültülü veri kümelerinde başarı ile uygulanmış, hızlı ve etkin çözümler elde edilmiştir [16].

Meta-sezgisel algoritmalar ile kural öğrenme yaklaşımları, temelde Pittsburgh ve Michigan olmak üzere 2 farklı grup altında toplanabilir. Birinci grup algoritmalar Pittsburgh adı verilen kural araştırma stratejisini kullanır. Bu araştırma stratejisi ilk kez 1980 yılında Smith tarafından tamamlanmış doktora tezinde (LS-1) adı verilen GA'ya dayalı geliştirilen algoritmada kullanılmıştır. GA'ya ait her bir araştırma çözümü, veri kümesinin tamamını modelleyebilecek türde bir kural kümesi araştırmaktadır.

Algoritma çalıştığında bulunacak en iyi birey, veri kümesinden indirgenen sınıflandırma modeli çözümüdür. Araştırma bireyinin kaç kurallık bir model araştırması gerektiğinin belirsizliği bu tür algoritmaların en büyük dezavantajıdır. Literatüde sabit uzunlukta ya da dinamik uzunlukta araştırma bireyleri kullanan çeşitli algoritmalar geliştirilmiştir. İkinci gruptaki algoritmalar, Michigan adı verilen kural araştırma stratejisi kullanır. Meta-sezgisel algoritmanın popülasyonundaki her bir çözüm (kromozom, yol, yiyecek kaynağı, pozisyon), asıl çözümün bir parçasını yani, sadece tek bir kural temsil eder. İlk kez 1986 yılında Holland ve arkadaşları tarafından ortaya konulan CS-1 adlı GA temelli sınıflandırıcı sisteminde bu yaklaşım kullanılmıştır. Michigan stratejisinde, kuralların hepsini bulmak için iki farklı yaklaşım geliştirilmiştir. Bunlardan birincisi klasik sezgisel kural öğrenme algoritmalarında da olduğu gibi kuralların ardışık biçimde sırasıyla araştırılmasıdır. Her bir kural bulundukça karşılanan örnekler çıkartılır. Belirlenen kriter karşılanıncaya kadar yeni bir kural bulmak için meta-sezgisel algoritma yeniden çalıştırılır. Bu tür algoritmalar, meta-sezgisel algoritmaların tekrar çalıştırılması gerektiğinden dolayı diğer tür algoritmalara göre yavaş kalmaktadır. Sınıflandırıcı kurallarının bir arada öğrenilememesi nedeniyle elde edilecek kuralların arasında tekrarlayan, birbiri ile çelişen ve gereksiz kuralların bulunması, verideki gürültüden kaynaklanan yanlış kuralların bulunması söz konusu olabilmektedir. Bunların önüne geçmek için budama yaklaşımları ortaya konulmuştur. Michigan stratejisine dayalı ikinci yaklaşımdaki algoritmalar, meta-sezgisel algoritmayı bir kez çalıştırarak kural kümesini öğrenmektedir. Algoritmanın her bir bireyi yine tek bir kural temsil etmektedir. Ancak algoritma tek bir çözüme odaklanmak ve araştırmak yerine, veri kümesini en genel biçimde kapsayacak problemi çözmek için işbirliği yapmış farklı bireylerden oluşan çözüm kümesi önermektedir. Önerilen çözüm kümesi, eğitim verileri üzerinde değerlendirilir. Algoritma çalışması tamamlandığında bir grup birey, sınıflandırma modelini ortaya koyar. Böylece meta-sezgisel algoritma bir kez çalıştırıldığında kuralların hepsini keşfedebilmektedir [30–32].

Tezin Amacı

Tez çalışmasının amaçları şu şekilde sıralanabilir:

- Yapay Arı Koloni (ABC) algoritması farklı sahalardaki zor problemler üzerinde

başarı ile uygulanmıştır [78, 79]. Ancak veri madenciliği çalışmalarında yeterince kullanılmamıştır. Bölgesel çözümlere takılmadan hızlı biçimde küresel eniyi çözümü bulma kabiliyetine sahip bir meta-sezgisel algoritma olan ABC algoritmasının hangi veri madenciliği problemlerinin çözümü için uygun olabileceğinin araştırması yapılacaktır.

- Mevcut meta-sezgisel temelli kural öğrenme metotlarında yer alan eksiklikler gözönüne alınarak, kural öğrenimi için gürültülere karşı daha kararlı ve yüksek genelleştirme kabiliyetine sahip ABC tabanlı yeni yöntemler geliştirilecektir.

- Michigan yaklaşımına dayalı tekrarlı kural öğrenen ABC tabanlı bir kural öğrenme algoritması geliştirilecek ve literatürdeki diğer yaygın yöntemler ile karşılaştırılacaktır.

- Tekrarlı öğrenme yönteminde kuralların ayrı ayrı öğreniminden kaynaklanan yavaşlık ve düşük doğruluk problemlerinin giderilmesi amacıyla, Michigan yaklaşımına dayalı işbirlikçi öğrenme yapabilen ABC tabanlı yeni bir kural kümesi öğrenimi algoritması geliştirilecek ve performansının değerlendirilmesi yapılacaktır.

- Günümüz veri işleme teknolojisindeki ilerlemeler doğrultusunda ortaya çıkan eş zamanlı çevrim içi öğrenme ihtiyacına cevap verebilecek türde, ABC ile kural tabanlı sınıflandırıcı çevrim-içi öğrenme algoritması geliştirilecek ve diğer algoritmalar ile karşılaştırılacaktır.

Tezin Organizasyonu

Yapay Arı Koloni (ABC) algoritması tabanlı yeni veri madenciliği algoritmaları öneren bu tezin düzenlemesi şu şekildedir.

1. Bölümde, literatürdeki veri madenciliği ve çözüm yöntemleri özetlenmiş, sınıflandırma problemi tanımlanmış, veri madenciliği yaklaşımı ile geliştirilen sezgisel çözüm yöntemleri açıklanmış ve sınıflandırma problemleri için literatürdeki kural öğrenme algoritmaları genel hatları ile anlatılmıştır.

2. Bölümde, öncelikle Yapay Arı Koloni algoritması (ABC) hakkında kısa bilgi verilmiş daha sonra ABC tabanlı ABC-Miner algoritması önerilmiştir. Geliştirilen yeni algoritma, veri kümesi üzerinden eğer-ise kuralı öğrenebilmektedir. Test problemleri üzerinde

yapılan deneyler sonucu performansı literatürdeki diğer sınıflandırma algoritmalarının performans sonuçları ile karşılaştırılmıştır.

3. Bölümde, ABC'ye dayalı geliştirilmiş işbirliği yaklaşımıyla kural öğrenen CoABC-Miner algoritması önerilmiştir. CoABC-Miner kural kümesini tekrarlı çalışmaya ihtiyaç duymadan bir kez çalıştırmayla öğrenebilmektedir. Algoritmanın performansı test problemleri üzerinde çok sayıda denenerek diğer algoritmaların performansları ile karşılaştırılmıştır.

4. Bölümde, ABC algoritmasına dayalı geliştirilen bir çevrim-içi kural öğrenme algoritması olan Online ABC-Miner önerilmiştir. Online ABC-Miner sürekli veri akışına sahip farklı sınıflandırma problemleri üzerinde test edilmiş ve performansı literatürdeki kural tabanlı çevrim-içi algoritmalarının performans sonuçlarıyla karşılaştırılmıştır.

5. Bölümde, tez çalışması süresince elde edilen sonuçlar özet olarak verilmiş, sonuçların yorumlanması yapılmış ve literatürde bu alanda gelecekte yapılması gereken çalışmalar hakkında öneriler verilmiştir.

Ek Bölümü'nde algoritma performanslarının karşılaştırması için kullanılan test problemleri hakkında detaylı açıklama yapılmış, yeni yöntemlerle keşfedilen sınıflandırma kuralları ile her bir deneyin sonuçları verilmiştir.

1. BÖLÜM

VERİ MADENCİLİĞİ YÖNTEMLERİ

Bu bölümde ilk önce veri madenciliği ile ilgili temel kavramlar tartışılacak daha sonra, veri madenciliği problemlerinin çözümleri için geliştirilmiş metodolojiler, bilgi keşfi için kullanılan bilim dalları ve çözüm araçları hakkında genel bilgi verilecek ve son olarak da sınıflandırma problemleri çözüm yöntemleri detaylı biçimde incelenecektir.

1.1. Veri Madenciliği

Veri madenciliği bilim dalı, verideki fark edilemeyen ilginç ve anlamlı bilgileri keşfetmek amacına yönelik veri analiz metotları geliştirmeyle ilgilenir. Artarak çok büyük boyutlara ulaşan ham veri yığınlarının içinden kullanışlı, verimli ve değerli bilgiye ulaşma ihtiyacı, veri madenciliği ve veritabanından bilgi keşfi kavramlarını ortaya çıkarmıştır. Yapılan çalışmalarda kullanılan ve birbiri ile ilişkili olan veri, bilgi ve bilgi ürünü kavramları, veri madenciliği metodolojisi, algoritmaları ve uygulamalarında kullanılmaktadır. Bundan dolayı öncelikle bu kavramların tanımı yapılacaktır.

1.1.1. Veri, Bilgi ve Bilgi Ürünü

Veri (data): Veri; tekil kişi, nesne, olay veya zaman hakkında fikir veren farklı niteliklerden meydana gelmiş, veritabanı vb. biçimde bir araya getirilip arşivlenebilmiş çok sayıdaki varlığın fiziksel nicelik değerleri topluluğudur [15, 18]. Meteorolojik hava ölçümleri, alışveriş tercihleri, faturalar, muayene tahlil sonuçları, telefon aramaları, gönderilen smsler, twitter kayıtları, internet izleri, sanayideki seri üretim bandı performans kayıtları, hisse senedi hareketleri, sayısallaştırılmış ses kaydı, astronomik görüntülemeler, büyük hadron çarpıştırıcısı deney sonuçları, insan genomundaki DNA

dizisi ve öğrencilerin elde ettikleri sınav puanları veriye örnek gösterilebilir. Bir veri parçacığını ifade etmek için örnek, varlık, kayıt veya satır gibi farklı isimler kullanılmaktadır. Veri, tek başına tüm sistem hakkında anlamı olmayan ham nicelikler yığınıdır. Günümüzde çeşitli uygulamalarda çok sayıda öznitelik (attribute) içeren kayıtlar tutulmaktadır. Aynı tür veri toplayan farklı veritabanı kaynakları birleştirilmek istendiğinde, tasarımdan kaynaklanan farklılıklar ortaya çıkabilecektir. Bu gibi veri birleştirme işlemlerinde, gürültü sayılabilecek durumlar temizlenmeli, aynı öznitelikler arasındaki tutarsızlıklar veri tipi dönüşümü ile giderilmelidir [15, 18, 33]. Verinin işlenebilmesi için toplama ve depolama sırasında aşağıdaki verilen kalite kriterleri sağlanmalıdır [11];

- Verinin doğruluğundan emin olunmalıdır. Örneğin farklı kaynaklarda aynı anlama gelen kısaltmalar, imla hatası gibi yazılış farklılıkları olabilir. Bu gibi farklılıklar analiz sırasında yanlışlığa sebep olmaktadır.
- Toplanan veriler, yeterli ve uygun veri tipi ile kaydedilmelidir. Örneğin hassasiyet kaybı olmaması için kayan noktalı sayı ile ifade edilmesi gereken bir veri tam sayı ile kaydedilmemelidir.
- Verinin bütünlüğü korunmalıdır. Örneğin farklı kaynakdan gelen veriler, aynı ölçü birimi ile toplanmış olmalı, birbiri ile tutarlı olmalıdır.
- Veri, tekrarlayan kayıtlar gibi gereksiz içerik barındırmamalı, veri olabilecek en az boyutta olmalıdır.
- Veri, öznitelik değerlerinde eksik ölçüm içermemelidir.

Bilgi (information, pattern): Veri topluluğunda yapılan analiz ve hesaplamalar sonucu keşfedilen yararlı, ilginç ve öz veriye bilgi denir [15]. Bilgi uzman kişilerce yapılan bilimsel çalışmalar sonucunda klasik veri analizi ile ortaya çıkartılabilmiştir. İletken, yarı iletken maddelerin elektriksel davranışlarının keşfedilmesi, bilim adamlarınca yapılan gözlemler ve bunların genelleştirilmesi ile ortaya çıkarılmış bilgiye bir örnek verilebilir. Günümüzde, klasik veri analiz yöntemleri ile başedilemeyecek karmaşıklıktaki problemler için istatistik, makineli öğrenme ve yapay zeka tekniklerine

dayalı otomatik/yarı otomatik yöntemler ile bilgi çıkarımı gerçekleştirilmektedir. Veri madenciliği ile ortaya konulan bu çıkarım, insan tarafından anlaşılabilir ve okunabilir biçimde olabildiği gibi sadece bilgisayarca işlenebilir kapalı kutu biçiminde de olabilmektedir.

Bir market zincirinin farklı bölgelerde faaliyet gösteren şubelerinde gerçekleşen satış verilerinin analiz edilmesi ve hangi ürünlerin nerde ve ne zaman tercih edildiği ve dönemsel satış artışlarının ortaya konulması veriden çıkartılmış bilgiye örnek olarak verilebilir [10].

Bilgi ürünü (tecrübe, knowledge): Keşfedilen bilginin sistem hakkında farklı karar ve tahminler yapmak amacıyla kullanılır biçime dönüştürülmesine bilgi ürünü denilmektedir [33]. Yarı iletken maddelerin keşfedilmesinin ardından transistör adı verilen bir ürünün kullanılmaya başlanması klasik yöntemler ile önceki dönemlerde çıkartılmış bir bilgi ürününe örnek olarak verilebilir.

Bir markette satış analizi sonucu elde edilen bilgiye dayanarak, raf diziliminin iyileştirilmesi, özel ürünlere talebin artacağı dönemlerde yapılan kampanyalar vb. ile kârlılığın ve verimliliğin artırılması veri madenciliği yöntemleri ile keşfedilmiş bilgi ürünü için örnek olarak verilebilir [10].

1.1.2. Veri Madenciliği ve Bilgi Keşfi için Kullanılan Bilim Dalları

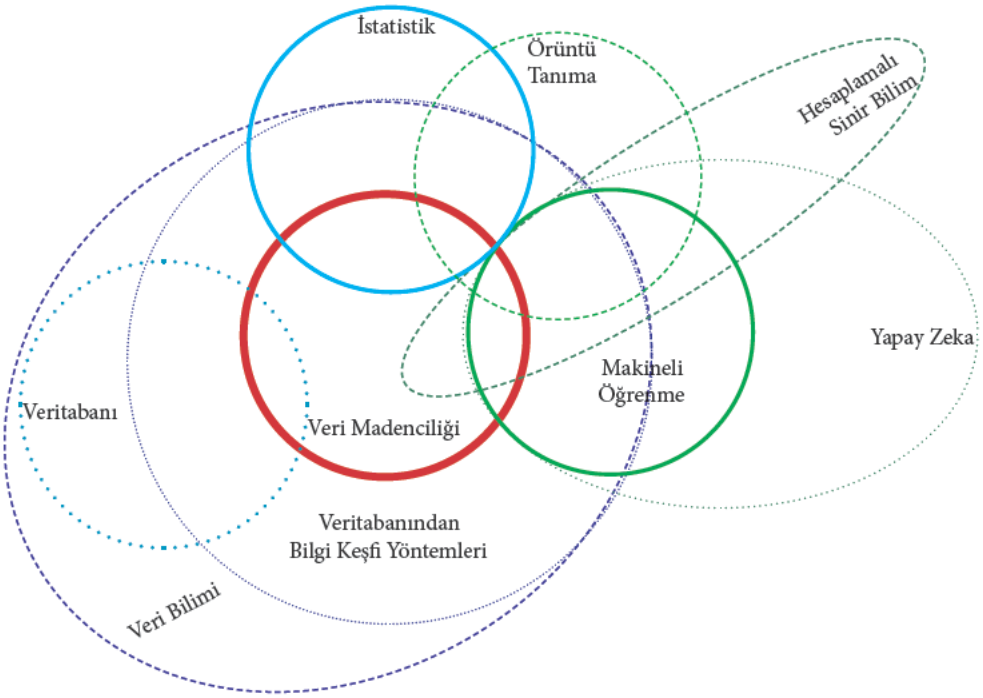
Bilgi keşfi ve veri madenciliği yaklaşımları, geneli özetleyici (tanımlayıcı) ve yeniyi tahmin edici olmak üzere iki farklı amaca yönelik kullanılır. Birinci grup özetleyici yaklaşımlar toplanmış mevcut veri yığını üzerinde istatistik tabanlı işlemler gerçekleştirir. Böylece geçmiş olaylar hakkında özetleme ve yorumlama yapılabilecek öz bilgi elde edilir. İkinci grup tahmin edici yaklaşımlar sistemin davranışını ortaya koyan bir model geliştirerek sonraki durumları tahmin etmeye çalışır. Model öğrenme işlemi geçmiş verilerin analiz edilerek girdi çıktı öznitelikleri arasındaki bağıntının ortaya çıkartılması problemidir. Sonra karşılaşılan yeni bir durumu daha önce öğrenilmiş bu ilişki modeli ile değerlendirir ve bilinmeyen değişken için tahmini bir değer hesaplanır. Veri madenciliği teknikleri için matematik ve istatistik bilimi, bilgisayar yazılımı ve veritabanı, örüntü tanıma, makineli öğrenme ve yapay zeka teknikleri gibi bir çok farklı disiplin araç olarak

bir arada kullanılmaktadır [20]. Şekil 1.1'de çeşitli bilim dallarının veri madenciliği ile olan etkileşimi gösterilmiştir. Bu bölümde veri madenciliği ve bilgi keşfi için kullanılan disiplinler hakkında kısaca bilgi verilecektir.

Matematik ve istatistik: Gözlem ve deney yolu ile elde edilen veriyi toplama, analiz etme, birleştirme ve özetleme amacıyla ortaya konulan matematiksel çalışmalara istatistik denir. Son yüzyıldaki istatistik çalışmalarında, verinin toplandığı alan hakkında yorumlayıcı ve kestirimci bilgi çıkarımı olmak üzere iki grupta yaklaşımlar ortaya konulmuştur. Ana kütlenin tamamının örneklenemediği durumlarda belirli sayıda veri ile istatistik değerleri hesaplanır. Ana kütle parametresi hakkında, güven aralığı ile verilen ihtimal yüzdesi içinde olasılık teorisine dayalı yaklaşık tahmin yapılabilir. İstatistik hesaplamalar veri madenciliğinde yaygın biçimde kullanılmaktadır. İstatistik yöntemler; regresyon, sınıflandırma, varyans ve zaman serisi analizi gibi amaçlarla kullanılmaktadır. Naif Bayes sınıflandırıcılar, saklı Markov modeli ve Bayes ağları istatistik tabanlı sınıflandırma yaklaşımlarıdır [15, 34].

Bilgisayar yazılımı ve veritabanı: Yazılım, bilgi işlem amacıyla ortaya konulmuş genel amaçlı elektronik aygıtların komut seti yardımıyla, bir problemin çözümü amacıyla yapılması gereken hesaplamalar için tanımlanmış makine komutları bütününe verilen isimdir. Günümüzde yazılımlar amaçlarına göre aygıt sürücüleri, işletim sistemleri, fonksiyon kütüphaneleri, sunucu yazılımları, veritabanları ve uygulama yazılımları olmak üzere farklı kategorilere ayrılmaktadır. Yazılım; elektronik sayısal tasarıma dayalı makine dilleri, makine komut setinin kısa komut etiketleri ile tanımlandığı assembly dili, donanım kavramlarından soyutlanmış ve konuşma dilindeki kelimeler ile tanımlanan orta seviyeli diller, görsel tasarım ve nesne yönelimli tanımlama yapılabilen yüksek seviyeli diller olmak üzere farklı yöntemlerle geliştirilebilir.

Veri analizi ve madenciliği için veritabanları ve çeşitli hesaplama yazılımları kullanılmaktadır. Veritabanı yazılımı birbiri ile ilişkili verilerin bir arada hiyerarşik biçimde tutulması için geliştirilmiştir. Sahip olduğu ilişkisel veritabanı yönetim araçları ile veriler hızlı ve kolay biçimde işlenebilir. Tanımlanacak ilişkisel veri modeli kriterleri doğrultusunda veriler veritabanı üzerinde saklanır. Toplanan kayıtlar için yapılması gereken sıralama, sorgulama, yedekleme ve güvenlik işlemleri veritabanı



Şekil 1.1. Veri madenciliği ve bilgi keşfi için kullanılan bilim dalları [20].

yönetim sistemi yazılımı tarafından gerçekleştirilir. Veri madenciliği yapılabilmesi için toplanan verilere hızlıca ulaşılabilmesi ve sorgulanabilmesi gerekir. Veritabanı yazılımları listeler, kuyruklar, ağaçlar ve graflar olmak üzere temel veri yapılarına dayalı çeşitli arama, sıralama, dosya işleme ve indeksleme algoritmaları yardımıyla en hızlı şekilde verileri işlemeye çalışır. Veritabanı yönetim sistemleri yazılımlarının temeli 1950'li yıllarda geliştirilen rapor üretim ve komut kontrol sistemlerine dayanmaktadır. Rapor üretim yazılımları çok sayıda verinin incelenerek karmaşık raporlar üretilmesi için geliştirilmiş yazılımlardır. CODASYL adlı programlama dili birliğinin Veritabanı Görev Grubu (Database task group, DBTG) tarafından 1969 yılında yayınlanan öneri yayınında veritabanı yönetim yazılımlarının temeli ortaya konulmuştur. Bu yayında, günümüz veritabanı yazılımlarında da kullanılan veri tanımlama diliyle (DDL) veri işleme dilinin (DML) anlamsal ve sözdimi kuralları yer almıştır. 1976'da farklı tablolar arası ilişkiyi tanımlayan varlık-ilişki yaklaşımı ortaya konulmuştur [6]. Günümüzde kullanılan veritabanı sorgulama dili (SQL) ilk kez verilerde ilişkisel model adı altında 1970 yılında yayınlanmıştır [35]. SQL 1986 yılında ANSI tarafından standart veri sorgulama dili olarak kabul edilmiştir [7, 8].

Yapay zeka teknikleri, örüntü tanıma ve makineli öğrenme: İnsanın sahip olduğu zeka, düşünme, sonuç çıkarım ve karar verme gibi bilişsel kabiliyetlerinin modellenmesi ve benzetim çalışmalarının tamamı yapay zeka bilim dalı altında incelenmektedir. Yapay zeka alanının ilgilendiği problemlerden bazıları; model çıkarım, planlama, öğrenme, doğal dil işleme olarak sıralanabilir. Yapay zeka bilimi; insan davranış ve karar mekanizmasının modellenmesinin yanında doğadaki zeki davranışların da bilgisayar hesaplamasına entegre edilmesi ile gelişmiş ve genişlemiştir. Bundan dolayı yapay sinir ağları, doğal dil işleme, konuşma anlama ve sentezleme, uzman sistemler, evrimsel algoritmalar, meta-sezgisel optimizasyon algoritmaları ve sürü tabanlı optimizasyon algoritmaları ve makineli öğrenme gibi farklı alt dallar altında geliştirilen yaklaşımların tamamını kapsamaktadır. Örüntü tanıma, belge analizi ve bilgi çıkarımı, görüntü işleme ve tanıma, parmak izi, el yazısı, ses ve yüz tanıma gibi biyometrik uygulamalar için ölçülen fiziksel niceliklerin kategorilere ayrılması nesnelerin tanınması çalışmaları örüntü tanıma olarak adlandırılır. Bu tür problemlere istatistik ve yapay zeka tekniklerinin kullanılmasıyla çözümler geliştirilmesi örüntü tanımanın ilgi alanına girmektedir [36].

Bilgisayarın belirli bir performans kriterini sağlayacak biçimde geçmiş deneyimler ve veriler kullanılarak programlanmasına makineli öğrenme denir [17]. Sebep sonuç arası kuralların veya matematiksel bağıntıyı ifade edecek net denklemlerin çıkartılması tümevarım yöntemleri ile gerçeklenebilir. Klasik yöntemlerin bilgisayar hesaplamasındaki zorluk ve süre kısıtı gibi nedenlerle mümkün olmadığı ya da bağıntının koşul ve durumlara göre değişkenlik gösterdiği karmaşık problemler için sezgisel makineli öğrenme yaklaşımları geliştirilmiştir. Makineli öğrenme algoritmaları denetimli (supervised), denetimsiz (unsupervised), yarıdenetimli (semi-supervised) ve pekiştirici (reinforcement) öğrenme olmak üzere alt gruplara ayrılmaktadır. Girdi öznitelikleri ve sistemin buna karşı verdiği çıktı değerlerinin bir arada analiz edilebildiği durumlarda denetimli öğrenme yaklaşımları, sistem hakkında toplanan verilerden sadece bir kısmının çıktı parametresinin değerinin bilindiği durumlarda yarı-denetimli öğrenme yaklaşımları, sistemin cevabının bilinmediği sadece girdi verilerinin var olduğu durumlarda denetimsiz öğrenme yaklaşımları, girdi durumuna karşılık sistemin tepkisinin dolaylı yoldan ödül ya da ceza gibi bir geri besleme ile öğrenilebildiği durumlarda ise pekiştirici öğrenme

yaklaşımları kullanılır [11, 20, 37].

1.1.3. Veri Madenciliği Problemleri ve Çözüm Araçları

Veri madenciliği problemleri ve çözüm araçları; kümeleme, birliktelik kuralları keşfi, aykırılık tespiti ve sınıflandırma olmak üzere farklı gruplarda incelenmektedir. Problemleri çözebilmek için literatürde çok çeşitli yaklaşımlar ortaya konulmuştur.

Kümeleme

Veri yığınındaki yakınlık ölçütleri çerçevesinde birbirine benzerlik gösteren varlıkların bir arada gruplanması işlemine kümeleme denir. Büyük veritabanlarında her bir kaydın hangi tür bir çıktı değerine sahip olduğu bilinmesi mümkün olmayabilir. Bundan dolayı kümeleme yaklaşımları veri kümesini bir bütün olarak ele alarak öz bilginin araştırılmasını gerektirmektedir. Örneğin bir marketin, müşteri davranışlarını inceleyerek benzer alışveriş alışkanlıkları olan müşterilerini belirlemesi ve onlara özel kampanyalar geliştirmesi kümeleme problemine verilebilecek bir uygulama örneğidir. Kümeleme teknikleriyle elde edilecek bir grup içindeki her verinin birbirine olan benzerliği yüksek seviyede olmalı, farklı gruplarda yer alan verilerin birbirine olan benzerliği ise en düşük seviyede olmalıdır [18].

Kümeleme algoritmaları, hiyerarşik kümeleme, merkezi prototip kümeleme, yoğunluk bazlı kümeleme ve dağılım modeli tabanlı kümeleme olmak üzere alt gruplara ayrılır. K-Means, DBSCAN (density-based spatial clustering of applications with noise), EM (expectation maximization) ve Birch (balanced iterative reducing and clustering using hierarchies) algoritmaları farklı kümeleme türüne verilebilecek birer örnek yöntemdir [15, 18]. Hiyerarşik kümeleme yaklaşımları veri kümesini dendogram adı verilen küme ağacı şeklinde hiyerarşik parçalara ayırmaktadır. Yığılımlı (agglomerative, bottom-up, alttan yukarı) ve bölücü (divisive, top-down, tepeden aşağı) olmak üzere veriler arasındaki ayrıştırmayı gerçekleştirir. Birch algoritması kümeleme özelliği (CF, clustering features) ve kümeleme özelliği ağacı (CF-Tree) adı verilen iki yeni kavram ile devasa boyuttaki veri kümelerini hızlı biçimde tarayarak kümeleyen hiyerarşik algoritmalara bir örnek olarak verilebilir [38]. K-Means algoritması ön tanımlı k sayıdaki gruba sahip bir prototipin grup merkezlerini en az hata ile belirleyen ve örneği en yakın merkezin grubuna atayan popüler

bir kümeleme yaklaşımıdır. Herhangi bir yeni kayıt en yakın olduğu merkez hangisi ise onun grubuna atanmaktadır [18, 39]. DBSCAN verilerin bölge üzerinde dağılım sıklığını inceleyerek yoğunluk bazlı kümeleme gerçekleştiren popüler bir kümeleme algoritmasıdır [40]. Maksimum benzerlik ölçütünü yinelemeli biçimde önce beklenti sonra maksimizasyon adımı ile hesaplayan bir yaklaşım olan EM algoritması ise dağılım modeli tabanlı kümeleme algoritmasına örnek olarak verilebilir [41].

Aykırılık tespiti

Bir sistem üzerinden toplanan veriler arasında ortaya çıkabilecek az sayıdaki farklı kayıtların belirlenmesi problemine aykırılık tespiti denir. Bu problemde, bir veritabanında yer alan kayıtların hepsinin belirli bir ortalama içinde genel davranış sergileyeceği kabulü ile analiz işlemleri gerçekleştirilir. Buna yönelik olarak çeşitli istatistik testler yoluyla dağılım ve olasılık hesapları gerçekleştirilmekte, genel kitle ile aynı dağılım istatistiği göstermeyen kayıtlar belirlenmektedir. Aykırılık tespiti yaklaşımları, genel davranış ve modele uymayan verilerin tespit edilmesi için sınırlamalı kümeleme yaklaşımlarını temel almaktadır. Diğer tür veri madenciliği problemlerinde uç noktalarda yer alan kayıtlar gürültü olarak adlandırılırken aykırılık tespiti çalışmaları bu tür kayıtları tespit etmeye odaklanmıştır. Örneğin kredi değerlendirme uygulamalarında kredi vermeye uygun olup olunmamasının belirlenmesinde bu tür teknikler kullanılmaktadır [15, 18].

Birliktelik Kuralları Keşfi

Birliktelik kuralları problemi, verilerin analizi sonucunda veri kümesinde sıklıkla birlikte gerçekleşen olayların keşfedilmesi işlemidir. Literatürde birliktelik kurallarına örnek olarak genellikle alışveriş sepetinin analizi gösterilmektedir. Bir marketin alışveriş kayıtlarının incelenmesi sonucu farklı gruplardaki bazı ürünlerin alışveriş sepetinde birlikte yer aldıkları ve birbiriyle yakından ilişkili olduğu keşfedilmiştir [15]. Agrawal tarafından 1994 yılnda önerilen Apriori algoritması veri kümeleri üzerinde birlikte meydana gelen kayıt gruplarını, kayıtların birlikte olma minimum destek frekansına göre tespit etmektedir [42].

Sınıflandırma

Sınıflandırma problemi, bir verinin bilinen bağımsız öznitelik değerlerinin analizi sonucu,

bu özniteliklere bağımlı olan başka bir özniteliğinin alacağı değerin tahmin edilmesi işlemidir. Sınıflandırma probleminde yukarıda tanımlanan problemlerden farklı olarak, verilerin girdi ve çıktı özniteliklerinin birlikte toplanması ve analiz edilmesi gerekir. Bağımlı özniteliğin değeri ya kategorik ya da sayısal bir değer olabilir. Kategorik türde öznitelik değeri daha önceden belirlenmiş sınıf kümesinde yeralan değerlerden birisi olabilir. Dolayısıyla geliştirilen sınıflandırma modeli giriş çıkış ağını ayrık biçimde ifade etmektedir. Çıkış özniteliğinin sayısal değer alması durumunda ise regresyon analizi gerçekleştirilir ve veriler ışığında çözüm uzayı üzerinde eğri veya yüzey modeli çıkartılmaya çalışılır. Model öğrenimi sürecinde eğitim verileri için yapılan tahminlerin gerçek değerlerle karşılaştırılması ile tahmin hatası hesaplanır. İşlem tamamlandığında tahmin hatası en az seviyeye indirgenmiş uygun bir sistem modeli elde edilir ve yeni karşılaşılacak durumlar için bağımlı değişken değerinin tahmini için kullanılır [10,11,33].

1.2. Veri Madenciliği Metodolojileri

Veri madenciliği bilim dalı, veri içinde normal şartlarda fark edilememiş ilginç ve anlamlı bilgileri keşfetmek amacına yönelik çalışmaktadır. Gregory Piatetsky-Shapiro 1989 yılında ilginç, kullanışlı ve yorumlanmış verinin bulunması tekniklerini ifade etmek için veritabanından bilgi keşfi (knowledge discovery from databases) terimini kullanmıştır. Günümüze kadar veri yığını içinden anlamlı öz bilginin keşfedilmesi işlemine veri madenciliği (data mining), veriden bilgi madenciliği (knowledge mining from data), bilgi çıkarımı (knowledge extraction), veri/örüntü analizi (data/pattern analysis), veri tarama (data dredging), bilgi keşfi (knowledge discovery) ve bilgi hasadı (information harvesting) gibi çeşitli isimler verilmiştir [15,43] . Büyük verilerden anlamlı öz bilginin çıkarılmasını ifade eden bilgi keşfi ve veri madenciliği tanımı diğerlerinin aksine günümüzde sıklıkla kullanılmaktadır [43].

Veri madenciliğinde ham veriden anlamlı sonuçlar çıkarmak için yapılacak işlem adımlarının hangi alanda uygulanırsa uygulansın aynı basamaklardan oluştuğu görülmüş, bunun için belirli bir standart çerçeve ortaya konulması, yapılacak işlemlerin, uygulama alanından bağımsız biçimde tanımlanması için literatürde çeşitli metodolojiler ortaya atılmıştır. 1996 yılında Fayyad ve arkadaşları 9 adımdan oluşan metodolojiyi ortaya atmıştır. 1998 yılında Cabena ve arkadaşları 5 adımdan oluşan farklı bir metodoloji

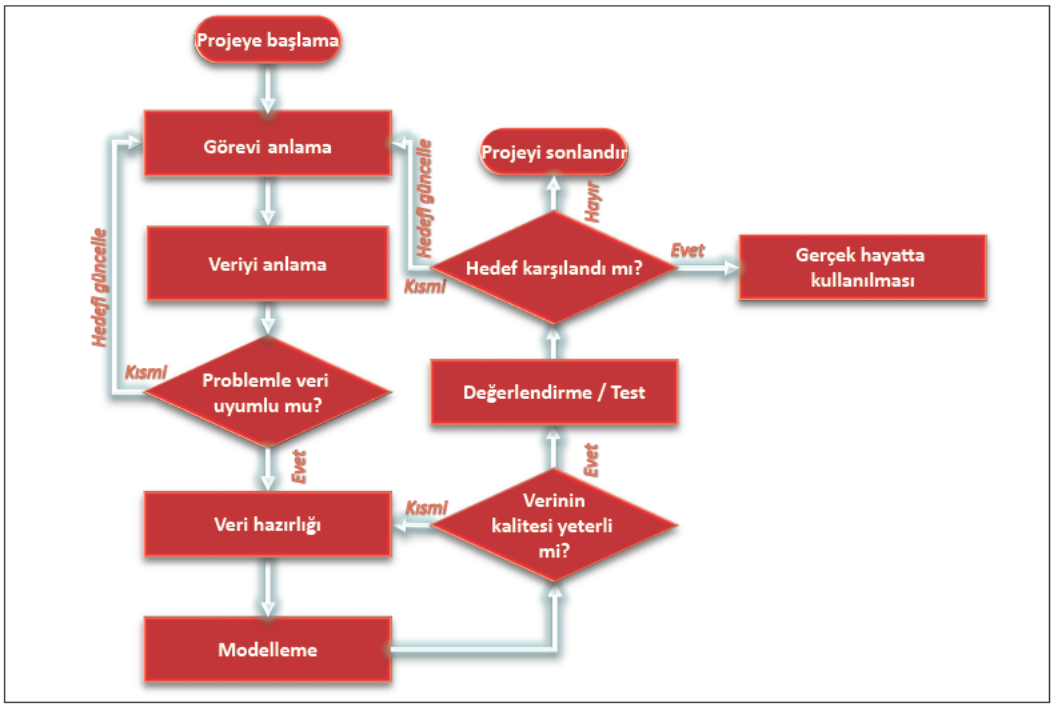
tanımlamıştır. Yine, 1998 yılında Anand ve arkadaşları sekiz adımdan oluşan bir yaklaşım ortaya koymuştur. Akademik alanda bunlar ortaya konulurken, SPSS, NCR, Daimler Chrysler ve OHRA şirketlerinden oluşan konsorsiyum ticari yazılımlarda ve iş hayatında kullanılmak amacıyla ilkini 2000 yılında yayınladıkları ve CRISP-DM (Cross industrial standard process for dm, Veri madenciliği için endüstriyel çapraz standart süreci) adıyla 6 adımdan oluşan standardı tanımlamıştır. Başka bir iş zekası yazılımı geliştirici SAS şirketi ise 5 adımdan oluşan SEMMA adını verdikleri kendi standardını duyurmuştur [14, 15, 43, 44].

1.2.1. Bilgi Keşfi ve Veri Madenciliği (KDDM) Süreci

U. Fayyad ve arkadaşları tarafından, 1996 yılında yayınlanmış makalelerde, bilgi keşfi ve veri madenciliği (KDDM) kavramını 9 adımdan oluşan bir süreç ile tanımlanmıştır. 1. adım, uygulama etki alanının anlaşılması ve geliştirilmesi işlemini içerir. 2. adım hedef bir veri kümesinin hazırlanması, toplanması işlemlerini kapsar. 3. adımda veri temizliği ve veri ön işleme süreçleri gerçekleştirilir. 4. adım, hedeflenen veri madenciliği tekniğine uygun biçimde veriyi hazır hale getirmek için verinin indirgenmesi ve projeksiyon işlemlerini tanımlar. 5. adımda belirlenen hedefler için uygun olacak veri madenciliği tekniği seçimi gerçekleştirilir. 6. adımda en uygun sonucu elde edebilmek için algoritma seçimi yapılır. 7. adımda veri üzerinde seçilen algoritma yardımıyla veri madenciliği işlemi yapılarak bilgi sınıflandırma kuralı, karar ağacı veya regresyon modeli vb. biçimde çıkartılır. 8. adım, çıkartılan örüntülerin yorumlanması, modele uygun verinin görselleştirilmesi işlemlerine dayanır. 9. adım, çıkartılan bilgi ürününün belgelendirme ve raporlar ile desteklenen sonuç sistemi halinde ortaya konulması sürecini tanımlar [10, 43].

1.2.2. CRISP-DM

CRISP-DM, 1996 yılında 4 şirketin ortak olduğu konsorsiyum tarafından geliştirilmeye başlanmış, 1997 yılında Avrupa Birliği ESPRIT projesine dönüştürülmüş ve 1.0 sürümü 2000 yılında yayınlanmıştır. CRISP-DM, "veri madenciliği için endüstriyel çapraz standart süreci" başlığındaki kelimelerin baş harflerinden oluşmaktadır. CRISP-DM, Şekil 1.2'de gösterildiği gibi süreci veya görevi anlama, veriyi anlama, veri hazırlığı,



Şekil 1.2. Veri madenciliği problemi çözümü için geliştirilmiş CRISP-DM yaklaşımının aşamaları.

modelleme, değerlendirme/test ve gerçek hayatta kullanım olmak üzere 6 adım ile tanımlamıştır. 1. görevi anlama adımında, veri madenciliği problem tanımı için uygun iş hedefi ve gereksinimlerini kavrama işlemlerini ifade eder. 2. adımda verinin araştırılması, veride olabilecek kalite problemlerinin tespit edilmesi, veriden gerekli ve ilginç alt kümenin seçilmesi işlemlerini kapsar. 3. adımda ham veriden, modelleme araçları ile kullanılabilecek biçimde temizlenmiş, dönüştürülmüş son veri için gerekli veri hazırlıklarının yapılması işlemlerini tanımlar. Bu aşama, hedefe ulaşabilmek için yinelenebilir. 4. adımda, temizlenmiş ve analize hazır hale getirilmiş verinin üzerinde çeşitli modelleme araçlarının kullanılmasını optimum sonuç elde edebilmek için parametrelerinin kalibrasyonu işlemlerini kapsar. Bir sonraki test değerlendirme aşamasında, gerçekleştirilen modellerin elde ettikleri başarılar değerlendirilir, gerçek hayatta kullanılmadan önce geçerliliği ve hedeflenen çıktıları verip vermediği değerlendirilir. Böylece veri madenciliği çıktılarının kullanılıp kullanılmayacağına karar verilir. Son aşamada ortaya konulan modelin kullanılabilir biçime getirilmesi, gereksinimler doğrultusunda çıktılarının hazırlanması işlemlerini tanımlar. CRISP-DM, bu aşamaların bir döngü halinde tekrarlanması gerekliliğini ortaya koyar [14, 43, 45].

1.2.3. Cabena (1998)

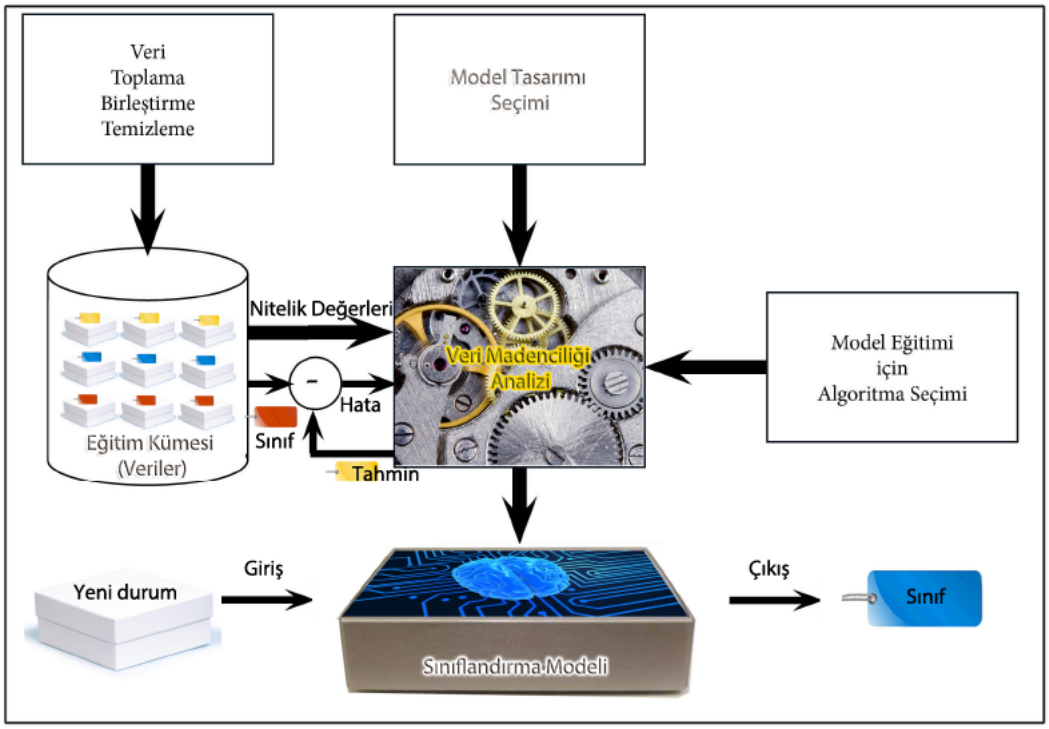
IBM'in desteklediği endüstriyel amaçlar gözönüne alınarak Cabena ve arkadaşları tarafından ortaya konulan veri madenciliği yaklaşımı beş adım ile tanımlanmıştır. CRISP-DM ile benzer olmasına rağmen veri anlama aşaması tanımlanmamıştır. Birinci adımda ticari problem ve ulaşılmak istenen hedefler belirlenir. 2. adımda veri hazırlığı gerçekleştirilir. Veri kaynaklarının belirlenmesi, gerekli verilerin seçimi, temizleme çalışmaları bu başlık altında gerçekleştirilir. 3. adımda hazırlanmış veri üzerinde veri madenciliği metotları uygulanır. 4. adımda sonuçlar incelenir, görselleştirme yapılır. 5. adımda ticari biçimde geliştirilen bilgi ürünü sunumu ve formülasyonu gerçekleşir.

1.2.4. SEMMA

SAS yazılım şirketi tarafından ortaya konulan SEMMA, örnekle (sample), araştır (explore), değiştir (modify), modelle (model), değerlendir (assess) kelimelerinin baş harflerinden meydana gelmektedir. Bu başlıklar ile tanımlanmış 5 adım ile veri madenciliği projelerinin geliştirilmesini amaçlar. SAS ticari yazılımında bu yaklaşım kullanılmıştır. 1. adım opsiyonel olup çok büyük miktardaki verinin içinden yeterli miktarda veriyi içeren alt kümesinin seçilmesini ifade etmiştir. 2. adım, veri kümesinin içide olabilecek anormal trend ve verilerin araştırılmasını ifade etmektedir. Bu aşama görsel ve istatistik yöntemler ile verinin incelenmesi gerçekleştirilir. 3. adımda seçilen modele uygun biçimde veriler üzerinde gerekli değişikliklerin yapılmasını ifade eder. 4. aşama hedeflenen çıktı için yazılımın otomatik araştırma yapmasını ve verinin modellenmesini tanımlar. Son aşamada ise elde edilen modelin başarısının, kullanışlılığının ve gerçeklenebilirliğinin değerlendirilmesi adımını tanımlar [12, 33].

1.3. Sınıflandırma Model ve Algoritmaları

Sınıflandırma modelleri, denetimli öğrenme ile giriş ve çıkış bir arada kullanılarak öğrenilir. Bunun için gerekli aşamalar, Şekil 1.3'te gösterilmiştir. Sınıflandırma probleminde ilk önce eğitim işleminde kullanılacak veriler toplanmalı ve bunlar üzerinde



Şekil 1.3. Sınıflandırma problemi çözüm aşamaları.

gerekli ön işlemler yapılmalıdır. Bu veriler, bağımsız-bağımlı öznitelik değerlerinden oluşan veri çiftlerini içerir ve Denklem 1.1'de verildiği gibi eğitim veri kümesi (S) olarak kullanılır. S, m adet örnekten oluşur. Her bir örnek n farklı bağımsız (x_k), ve bir bağımlı öznitelik (c_i^j), içerir. c_i^j, sistemin bağımsız öznitelik değerlerine karşı verdiği çıkış sınıfı değeridir. Sınıf değeri j farklı değerden herhangi birini alabilir.

$$S = \{(x_{i,1}, ..., x_{i,n}, c_i^j) | i = 1, ..., m\} \tag{1.1}$$

Bir sonraki aşamada hangi model biçimi kullanılacağı ve hangi algoritma ile eğitileceği belirlenir. Literatürde sınıflandırma için farklı biçimlerde modelleme yöntemleri geliştirilmiştir. Model biçimi, veriden indirgenerek ortaya konulacak giriş-çıkış ağının bilgisayar tarafından işlenebilir farklı tasarımlarla ifade edilmesidir. Eğer-ise kuralları, karar ağaçları, Bayes istatistik yaklaşımları, karar destek makineleri, örnek tabanlı yöntemler, matematik formüller, topluluk modeller ve yapay sinir ağları vb. çeşitli modelleme biçimleri geliştirilmiştir. Sınıflandırma modellerinin değerlendirilmesi için anlaşılırlık, basitlik, hız ve ölçeklenebilirlik gibi ölçütler kullanılır. Geliştirilmiş modeller bu parametrelerin hepsinde başarılı olamamakta, herbirinin farklı avantaj ve

dezavantajları bulunmaktadır. Hangi model şeklinin ve hangi öğrenme algoritmasının kullanılması gerektiği, problemin kullanım alanına uygun biçimde seçilmelidir. Hızlıca öğrenilen bir sınıflandırma modeli, anlaşılır ve basit bir model, ya da değişimlere karşı kararlı ve sağlam bir model elde etmek mi gibi sorular ile model ve öğrenme algoritması tercih edilebilir. Bir sonraki aşamada veriler hazır olduktan ve model ile algoritma tercihi yapıldıktan sonra model eğitimi gerçekleştirilir. Ortaya konulan model, artık sınıflandırma yapabilir. Ancak kullanılabilir olduğunun değerlendirilmesi gerekir. Bunun için de test verileri ile yaptığı sınıflandırmaların doğruluğunun sınanması gerekmektedir. Test işleminden başarı ile geçtikten sonra model yeni durumların sınıflandırılmasında kullanılır [10, 15, 18].

Algoritma tarafından öğrenme gerçekleştirilirken sistemin sebep-sonuç davranışını çözen, giriş-çıkış arası ilişki modeli (hipotezler) araştırılmalıdır. Sebep-sonuç ilişkisini %100 doğrulukla keşfedebilmek için her türlü olasılık karşısında sistemin nasıl davrandığının bilinmesi gerekir. Ancak pratikte, maliyet ve süre engelleri nedeniyle sistem hakkında yeterli veri toplamak mümkün değildir. Öğrenme algoritması en basit model yapısından başlar ve önerdiği modeli eğitim verileri ile karşılaştırarak genelleme yapmaya çalışır. Yapabileceği genelleme ile elde edilecek sınıflandırıcı gerçek sistem davranışına benzeyen yaklaşık bir çözüm olacaktır. Algoritmalar doğru sınıflandırıcı modelini bulabilmek için farklı arama metodolojilerinden birini kullanır. Bunlar, kapsamlı, rastgele (sistematik), sezgisel ve meta-sezgisel arama olmak üzere makineli öğrenme metodolojileridir. Birinci metodoloji, kapsamlı arama, bütün ihtimalleri denemeyi gerektirir. Yukarıda ifade edildiği gibi yeterli örnek toplanamadığı için bu mümkün değildir. İkinci metodoloji, rastgele (sistematik) arama, komşuluk çözümlerinin hepsinin sırasıyla denenmesini gerektirir. Eğitim verileri üzerinde kaba kuvvet yaklaşımı ile sistematik bir araştırma işlemi yapılması çok maliyetli ve uzun süren bir arama stratejisidir. Üçüncü metodoloji olan aç gözlü arama sezgisel stratejiler ile çözüm uzayında belirli bir doğrultuda araştırma gerçekleştirir. Gereksiz çözüm önerilerini denemeyi elediği ve sürekli daha iyi sonuç verecek yönde ilerlediği için çözüm uzayındaki olasılıkların deneme sayısı oldukça azaltılır. Ancak kullanılan ilerleme stratejisi en iyi çözüme ulaşmak yerine başlangıç noktasına bağlı yerel bir çözüme takılma riskini barındırır. Bunun önüne geçmek için dördüncü strateji olarak meta-sezgisel yaklaşımlar

geliştirilmiş, sezgisel ve rastgele araştırma adımları birlikte kullanılmıştır. Sezgisel ilerleme, çözümü iyiye doğru yönlendirirken, rastgele araştırma çözüm uzayındaki farklı bölgelerin de denenmesine şans verir [15, 16, 18, 21].

Her bir model biçimine yönelik birçok öğrenme yöntemi geliştirilmiştir. Bu yöntemlerden tez çalışması ile yakından ilgili olan karar ağaçları ve kural tabanlı sınıflandırma algoritmaları hakkında ayrıntılı bilgi verilmiştir.

1.3.1. Sınıflandırma Hataları ve Değerlendirme Ölçütleri

Öğrenme algoritmaları, geliştirilen sınıflandırma modellerinin doğruluğunu ya da amaçlanan başarısını belirli bir kalite fonksiyonu ile değerlendirmelidir. Bunun için algoritmaların kalite fonksiyonlarında kullanılan ortak ifade ve tanımlamalar bu kısımda verilecektir.

1.3.1.1. Hata matrisi ve Değerlendirme Ölçütleri

İkili sınıflandırma için yapılan bir önermenin istatistikî değerlendirilmesi amacıyla hata matrisi (kontenjans tablosu, karmaşıklık matrisi) adı verilen bir karşılaştırma tablosu (Şekil 1.4) kullanılır. Hata matrisinde verildiği üzere doğru tahmin edilen pozitif sınıflar için doğru pozitif (TP), doğru tahmin edilen negatif sınıflar için doğru negatif (TN), yanlış tahmin edilen negatif sınıflar için yanlış pozitif (FP) ve yanlış tahmin edilen pozitif sınıflar için yanlış negatif (FN) kavramları tanımlanmıştır. (TP); sınıfın gerçekte olmasıyla birlikte tahmininin de doğru yapılması iken (TN); sınıfın gerçekte olmaması durumuyla birlikte olmadığının da doğru tahmin edilmesidir. (FP); sınıfın gerçekte pozitif olmamasına rağmen yanlışlıkla pozitif olduğunun kabul edilmesi, (FN); sınıfın gerçekte pozitif olmasına rağmen yanlışlıkla negatif kabul edilmesi hatalarıdır. Tıbbi teşhis konulması üzerinden örnek verilirse, hastalığı olmayan birine hasta teşhisi konulması (FP), hastalığı olan birine de teşhis konulamaması (FN) olarak adlandırılır. İstatistik hipotez testinde boş (null) hipotezin reddedilmesi pozitif kabul edildiği için, doğru bir boş hipotezinin yanlışlıkla reddedilmesi istatistik tip 1 hatası (FP) olarak, yanlış boş hipotezinin reddedilmeme hatası ise istatistik tip 2 hatası (FN) olarak ifade edilir. (P); pozitif sınıfa sahip örnek sayısı, (N); negatif sınıfa sahip örnek sayısı, (PT); pozitif sınıf

		TAHMİN EDİLEN SINIF DEĞERİ		TOPLAM
		POZİTİF	NEGATİF	
GERÇEK SINIF DEĞERİ	POZİTİF	DOĞRU POZİTİF (TP)	YANLIŞ NEGATİF (FN) (Tip 2 Hatası)	Pozitif Gerçek Toplamı (P)
	NEGATİF	YANLIŞ POZİTİF (FP) (Tip 1 Hatası)	DOĞRU NEGATİF (TN)	Negatif Gerçek Toplamı (N)
TOPLAM		Pozitif Tahmin Toplamı (PT)	Negatif Tahmin Toplam (NT)	Toplam Örnek Sayısı (M)

Şekil 1.4. İkili sınıflandırma için hata matrisi.

tahmini yapılan örnek sayısı, (NT); negatif sınıf tahmini yapılan örnek sayısı, (M); toplam örnek sayısı değerlerini göstermektedir.

Şekil 1.4'te ikili sınıflandırma için hata matrisi verilmiştir. Hata matrisi kullanılarak aşağıda açıklanan değerlendirme ölçütleri hesaplanmaktadır.

- Duyarlılık (Doğru pozitif oranı, DPO): Duyarlılık ölçütü, sınıfı doğru tahmin edilen pozitif örneklerin toplam pozitif örnek sayısına olan oranıdır (Denklem 1.2).

$$DPO = \frac{TP}{P} = \frac{TP}{TP + FN} \tag{1.2}$$

- Belirlilik (Doğru negatif oranı, DNO): Belirlilik ölçütü, sınıfı doğru tahmin edilen negatif örneklerin toplam negatif örnek sayısına olan oranıdır (Denklem 1.3).

$$DNO = \frac{TN}{N} = \frac{TN}{TN + FP} \tag{1.3}$$

- Hassasiyet (Pozitif tahmin oranı, PTO): Hassasiyet, doğru biçimde tahmin edilen pozitif örnek sayısının, toplam pozitif tahmin edilen örnek sayısına olan oranıdır (Denklem 1.4).

$$PTO = \frac{TP}{PT} = \frac{TP}{TP + FP} \tag{1.4}$$

- Negatif tahmin oranı (NTO): Negatif tahmin oranı, doğru biçimde tahmin edilen negatif örnek sayısının toplam negatif tahmin edilen örnek sayısına olan oranıdır (Denklem 1.5).

$$NTO = \frac{TN}{NT} = \frac{TN}{TN + FN} \tag{1.5}$$

- Yanlış pozitif oranı (YPO): Yanlışlıkla pozitif kabul edilen negatif örnek sayısının, toplam negatif örnek sayısına oranıdır (Denklem 1.6).

$$YPO = \frac{FP}{N} = \frac{FP}{TN + FP} \tag{1.6}$$

- Doğruluk (TO): Bir sınıflandırıcının doğruluğu, doğru yapılan sınıf tahmini sayısının toplam örnek sayısına olan oranıdır (Denklem 1.7).

$$TO = \frac{TP + TN}{M} = \frac{TP + TN}{TN + TP + FP + FN} \tag{1.7}$$

- F1 skoru: Hassasiyet ve duyarlılığın harmonik ortalamasıdır (Denklem 1.8).

$$F1 = \frac{2 * TP}{2 * TP + FP + FN} \tag{1.8}$$

1.3.1.2. Entropi

Entropi, bilgi teorisi için bilgi kazancı hesaplanmasında kullanılan bir ölçüttür. Veri kümesindeki sınıf dağılımlarının hesaplanmasına dayanır. K_1, yapılan bir ayrıştırma sonucunda ortaya çıkan veri kümesinin bir alt kümesidir. p_i, K_1 içindeki C_i sınıfının olasılığıdır. m sınıf sayısı olmak üzere entropi Denklem 1.9'da verildiği şekilde elde edilir.

$$Entropi(D_1) = -\sum_{i=1}^{m} p_i \log_2(p_i) \tag{1.9}$$

1.3.1.3. Bilgi Kazancı

Karar ağaçlarındaki herhangi bir K düğümünün değerlendirilmesinde bilgi kazancı kullanılır. K düğümünün D örneklerini kapsadığı ve düğümde kullanılacak A ayrık özniteliğinin v farklı değer aldığı, böylece örneklerin $D1, D2, ..., Dv$ olmak üzere v alt kümeye ayrıştırıldığı varsayıldığında bilgi kazancı Denklem 1.10 ve 1.11 kullanılarak hesaplanır.

$$Bilgi_A(K) = \sum_{j=1}^{v} \frac{|D_j|}{|D|} * Entropi(D_j) \tag{1.10}$$

$$Kazanc(A) = Entropi(D) - Bilgi_A(D) \tag{1.11}$$

1.3.1.4. Gini İndisi

Gini indisi her bir öznitelik için ikili ayrıştırma yapıldığı varsayılarak hesaplanmaktadır. p_i, D içinde yer alan C_i sınıfına ait örneklerin, $|C_{i,D}|/|D|$ olasılığı ve m toplam sınıf sayısı olmak üzere Gini indisi Denklem 1.12 ile hesaplanır.

$$Gini(D) = 1 - \sum_{i=1}^{m} p_i^2 \tag{1.12}$$

1.3.1.5. Kural değerlendirme

Öğrenme yöntemi için Michigan sınıflandırma yaklaşımı kullanıyorsa, algoritma, popülasyon bireylerinin her birinin temsil ettiği kismi çözümlerin kalitelerinin ayrı ayrı değerlendirilmesine ihtiyaç duymaktadır. Değerlendirme sırasında Tablo 1.1'de verilen 4 farklı durum ortaya çıkmaktadır.

- Doğru pozitif (*TP*); kural ön şart kısmının olumlu karşıladığı (pozitif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olanların (doğru karar) sayısıdır.
- Yanlış pozitif (*FP*); kural ön şart kısmının olumlu karşıladığı (pozitif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olmayanların (yanlış karar) sayısıdır.
- Doğru negatif (*TN*); kural ön şart kısmının olumsuz olup karşılamadığı (negatif test

Tablo 1.1. Kural ile veri kümesi karşılaştırması.

Değerlendirme	Karşılaştırma Testi	Sınıf Kararı	Sınıf Benzerliği
Doğru pozitif (*TP*)	Pozitif	(Doğru karar)	Aynı sınıf
Yanlış pozitif (*FP*)	Pozitif	(Yanlış karar)	Farklı sınıf
Doğru negatif (*TN*)	Negatif	(Doğru karar)	Farklı sınıf
Yanlış negatif (*FN*)	Negatif	(Yanlış karar)	Aynı sınıf

sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olmayanların (doğru karar) sayısıdır.

- Yanlış negatif (*FN*); kural ön şart kısmının olumsuz olup karşılamadığı (negatif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olanların (yanlış karar) sayısıdır.

Sınıflandırma kuralı, veri kümesi üzerinde elde ettiği başarıya göre değerlendirilir. Değerlendirme için kapsama oranı ve doğruluk ölçütleri kullanılmaktadır. Bir kurala ait kapsama oranı, kuralın şart kısmının örtüştüğü örnek sayısının, veri kümesindeki toplam örnek sayısına oranı olmak üzere Denklem 1.13 ile hesaplanır.

$$kapsama(Kural) = \frac{örtüşen\_örnek\_sayısı}{N} = \frac{|Pozitif|}{N} \tag{1.13}$$

Bir kuralın doğruluk ölçütü ise, doğru karşılanan örnek sayısının, şartı ile pozitif örtüşen örnek sayısına oranı Denklem 1.14 ile hesaplanır.

$$doğruluk(Kural) = \frac{örtüşen\_doğru\_sınıflı\_örnek}{örtüşen\_örnek\_sayısı} = \frac{TP}{|Pozitif|} \tag{1.14}$$

1.3.1.6. Meta-sezgisel Algoritmalarda Kullanılan Kalite Fonksiyonu

Kalite fonksiyonu meta-sezgisel algoritmanın araştırma yönünü doğrudan etkileyen önemli bir faktördür. Bundan dolayı seçilecek kalite fonksiyonu vasıtasıyla çözüm istenen yönde geliştirilmeye çalışılır. Yapılacak değerlendirme, ortaya konulan kuralın şartının örneklerle hangi ölçütte örtüştüğü ve sahip olduğu sınıfın tahmin sınıfıyla olan benzerliğine göre Tablo 1.1'de verilen durumlarla incelenmektedir. Bir kuralın ön şart kısmı, verinin öznitelik değerleri ile karşılaştırılır, eğer örneği karşılarsa test pozitif

değilse negatif değer alır. Örnek ve kural sınıf değerleri aynı ise sınıf kararı doğru karar, sınıf değerleri farklı ise yanlış karar olarak değerlendirilir.

İdeal bir kural, kendi karar sınıfı ile aynı örneklerin hepsini karşılamalı (FN değeri sıfır) ve diğer sınıflı örneklerin hiçbiriyle örtüşmemelidir (FP değeri sıfır). İfade edilen ideal durumda kalite değeri 1 olan kalite fonksiyonu Denklem 1.15'te verilmiştir. Araştırılacak ideal çözümü ifade eden bu kalite fonksiyonu meta-sezgisel algoritmalar için sıklıkla kullanılmıştır [46].

$$Kalite(Kural) = Duyarlilik * Belirlilik = \frac{TP}{TP + FN} * \frac{TN}{TN + FP} \tag{1.15}$$

1.3.2. Karar Ağaçları

Karar ağaçları, sıklıkla kullanılan sınıflandırma modellerinden biridir ve şart düğümlerinden ve karar sınıf yapraklarından oluşur. Tepeden en alt düğüme gelinceye kadar bağımsız öznitelik değerlerini karşılaştırarak farklı dal ayrımları ile sınıfı belirlemeye çalışır. Ayırma düğümleri farklı dallar üzerinde birbiri ardınca konumlanmıştır. Bir şart düğümü, verinin özniteliklerinden birinin değerini kontrol eder, karar mekanizmasının iki ya da daha fazla alternatif yoldan uygun olanına doğru ilerlemesini sağlar. Karar ağacında yer alan her bir yolun sonunda, en altta karar yaprağı yer alır ve bağımlı özniteliğin alması gereken en uygun sınıf değeri belirtilir. Ortaya çıkartılan model, insanlar tarafından da anlaşılır bir sınıflandırıcı türüdür. Karar ağacı öğrenme algoritmaları veri kümesini sistematik biçimde parçalayarak küçültür ve verileri tamamen yok edinceye kadar karar ağacına ayrıntılı dallar ekler. Karar ağacı çıkarımı için istatistik yöntemlere dayalı çeşitli çalışmalar ortaya konulmuştur [47–49].

1.3.2.1. ID3 Algoritması

ID3 en temel karar ağacı algoritmalarından biridir. Düğümlerde yer alması gerekli öznitelik şartlarını belirlemek için bilgi kazancı ölçütü kullanılır. En yüksek bilgi kazancı sağlayan öznitelik, düğüme yerleştirilir. Belirlenen düğümler doğrultusunda veri kümesi parçalanarak alt kümelere ayrılır. Alt küme ayrıştırılması sadece bir sınıfa ait örnekler kalıncaya kadar ya da düğüm için kullanılabilecek başka bir öznitelik kalmayıncaya kadar

sürdürülür. Ayrıştırma tamamlandıktan sonra alt küme içindeki örnekler, tek sınıfa ait örnekler varsa karar ağacı yaprağına bu sınıf, farklı sınıflar içeriyorsa yüksek frekanslı sınıf yerleştirilir [48]. Algoritmanın kaba kodu Algoritma 1.1'de verilmiştir.

1.3.2.2. C4.5 Algoritması

C4.5 algoritması ID3 algoritmasını temel almıştır. Entropi ve bilgi kazancı hesaplaması yoluyla her bir düğümde hangi özniteliğin yer alacağı belirlenir. Algoritma karar ağacı öğrenimini tamamladıktan sonra modeli aynı zamanda sınıflandırma kurallarına da çevirebilmektedir. C4.5 algoritması hem sürekli ve hem de kategorik türdeki öznitelikler içeren veri kümelerine uygulanabilmektedir. Ayrıca eksik değerler ile de çalışabilecek

Girişler: *D*: Eğitim veri kümesi.
Öznitelik: Problemi tanımlayan kategorik öznitelik değerleri.
Çıkış : *KararAğacı*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan karar ağacı modeli.
Veri: $Kazanç$: Özniteliklerin bilgi kazancı değerleri.
$D_1, D_2, ..., D_n$: Belirlenen düğüm çerçevesinde veri kümesinin ayrıldığı alt kümeler.
$D_{i,Sınıf Özniteliği}$: D_i veri kümesi sınıf değerleri.
$D_{i,Sınıf}$: D_i örneklerinin sınıf değeri.
$ÖznitelikDüğümü$: Bilgi kazancı en yüksek öznitelik düğümü.

$KararAğacı$ = {}
`Prosedür DüğümEkle(`D`,`$KararAğacı$`)`:
$Kazanç$ =NiteliklerinBilgiKazançlarınıHesapla(D)
$ÖznitelikDüğümü$ = EnYüksekKazançlıÖznitelikSeç($Öznitelik$,$Kazanç$)
$KararAğacı = KararAğacı \cup ÖznitelikDüğümü$
$\{D_1, D_2, ..., D_n\}$=VeriKumesiniAltKumelereAyır(D,$ÖznitelikDüğümü$)
for ($i = 1 \cdots n$) **do**
  if ($D_i \neq \{\}$) **then**
    if ($|D_{i,Sınıf Özniteliği}| = 1$) **then**
      $Sınıf = D_{i,Sınıf}$
      $KararAğacı = KararAğacı \cup Yaprak(Sınıf)$
    else
      $DüğümEkle(D_i, KararAğacı)$
    end if
  end if
end for
end DüğümEkle.
return KararAğacı

Algoritma 1.1: ID3 algoritması kaba kodu.

şekilde uyarlanmıştır. Sürekli öznitelik değerlerini belirli bir sınır ile ikiye ayrıştırmakta ve karar düğümlerinde kullanmaktadır. Karar ağaçları elde edildikten sonra geliştirilen budama yaklaşımı ile arzu edilirse sadeleştirme yapabilmektedir. Algoritma Ockham'ın usturası teorisine dayalı olarak olabilecek en basit tanımı elde etmeyi hedeflemektedir. Algoritmanın kaba kodu Algoritma 1.2'de verilmiştir [48, 49].

Girişler: D: Eğitim veri kümesi.
a: Öznitelik değerleri.
Çıkış : *KararAğacı*: Keşfedilen karar ağacı modeli.
Veri: m: Öznitelik sayısı.
$KararAğacı$ = {}
Temel durumları kontrol et
for $(i = 1 \cdots m)$ **do**
a_i için normalleştirilmiş bilgi kazancını hesapla.
end for
En yüksek bilgi kazancını veren a_{best} ile düğüm ekle.
Yapılan dallanma üzerinde alt kümelere aynı biçimde yeni düğümler ekle.
Karar ağacı üretildikten sonra budama işlemi gerçekleştir.
return KararAğacı

Algoritma 1.2: C4.5 algoritması kaba kodu.

1.3.2.3. CART Algoritması

Sınıflandırma ve Regresyon agaçları (C&RT) algoritması veri kümesinden karar ağacı indirgeme için geliştirilmiş algoritmalarının genelini ifade etmektedir. Bununla birlikte aynı ismi taşıyan CART, Breiman ve arkadaşları tarafından geliştirilen çıkış niteliğinin türüne göre sınıflandırma veya regresyon ağacı öğrenmek için geliştirilmiş parametrik olmayan bir algoritmadır. Algoritma, ağacı düğümlerde ikili dallara ayrıştırır ve belirlenen kural sağlanıncaya kadar karar ağacı geliştirilmeye devam edilir. Dallara ayrıştırma işlemi yeterli kazanç elde edilemediği durumda sonlandırılır. Aynı zamanda önceden tanımlanmış farklı kriterler ile karar ağacı gelişimini sonlandırmak mümkündür. Algoritmanın kaba kodu Algoritma 1.3'te verilmiştir [50].

1.3.3. Kural Tabanlı Klasik Sınıflandırma Sistemleri

Literatürde çeşitli klasik yöntemlere dayalı kural öğrenme yaklaşımları geliştirilmiştir. Bu tür algoritmalar çeşitli analitik ve sezgisel yaklaşımlar kullanır. İstatistiksel

Girişler: D: Eğitim veri kümesi.
a: Öznitelik değerleri.
Çıkış : *KararAğacı*: Keşfedilen karar ağacı modeli.
Veri: m: Öznitelik sayısı.
Her öznitelik için geçerli bütün olası değerleri sırasıyla değerlendir.
a_i özniteliği için en uygun $a_i = t_1$ değerini seç
En yüksek ayrıştırmayı sağlayan $a_i = t_1$ ile yeni ikili düğüm ekle.
Veriyi alt kümelere ayrıştır.
Sol ve sağda kalan dallar için aynı şekilde yeni düğüm ekle.
Durdurma kriteri sağlanıncaya kadar ayrıştırmayı tekrarla.
return KararAğacı

Algoritma 1.3: CART algoritması kaba kodu.

değerlendirmeler yaparak veri kümesini küçük parçalara ayırır ve örnekler arası ortak noktaları genelleme yoluyla bulmaya çalışır. Sonunda, çözüm uzayını kapsayacak biçimde genelleştirilmiş kuralları keşfeder.

Karar ağacı ve kural öğrenme yöntemleri birbirlerine oldukça benzemektedir. Karar ağaçlarının en altta yer alan her bir sınıf yaprağından köke doğru gidildiğinde elde edilecek karar-karşılaştırmalar kombinasyonu bir kural olarak ifade edilir. Dolayısıyla karar ağacı yöntemleri ile elde edilen modeller sözel kurallara dönüştürülebilir. Karar ağaçları yukarıdan aşağıya doğru veri kümesini parçalayarak model öğrenimi gerçekleştirir. Kural tabanlı algoritmalarda ise veriler gruplara ayrılarak öğrenme gerçekleşir. C4.5 algoritması çıkartılan karar ağacının kurala dönüştürülmesi yoluyla kural öğrenimi için önerilmiştir. Literatürde AQ, CN2, IREP, RIPPER gibi çeşitli aç gözlü kural öğrenme metotları geliştirilmiştir [15, 32, 51, 52].

Kural tabanlı sınıflandırma sistemleri hem makine hem de insan tarafından anlaşılır ve yorumlanabilir önermelere sahiptir. Bir eğer-ise önerme kuralı; **eğer** ve **ise** kısımları olmak üzere iki parçaya sahiptir. Kuralın genel yazılış biçimi aşağıda verilmiştir.

EĞER [Şart] İSE: [Karar]

$$Eğer \quad \{Test_1 \bigwedge \cdots \bigwedge Test_m\} \quad İSE \quad Sınıf = S_J$$

EĞER (N_1 = $değer_{1,x}$) *VE* $\cdots$ *VE* (N_m = $değer_{1,z}$) *İSE* *Sınıf* = S_J

Kuralın birinci kısmı (*Eğer*) kesin sınırlar ile tanımlı şart kısmını ifade eder ve bağımsız öznitelikler ile yapılan karşılaştırma testlerini içerir. Bir karşılaştırma testi; öznitelik, karşılaştırma değeri ve test operatörün olmak üzere üç kısımdan meydana gelir. Karşılaştırma değeri özniteliğin alabileği bir sayısal ya da kategorik türde bir değerdir. Kullanılan operatör, öznitelik türüne göre farklılık gösterir. Öznitelik sayısal türde ise büyük/küçük/eşit ($>, <, =$) operatörlerinden biri kullanılır. Öznitelik kategorik ise eşitlik/farklılık (=,$\neq$) operatörleri ile ifade edilir. Şartta yer alan testler mantıksal bağlaçlarla (ve/veya) bağlanmıştır.

Kuralın ikinci kısmı (*ise*) karşılaştırmanın doğru olması durumunda verilecek kararı tanımlar. Sistemin çıkışını ifade edecek bu karar, bağımlı değişkenin önceden tanımlanmış sınıf değerlerinden birisidir.

Bir kuralın şart kısmındaki karşılaştırmalar ile kapsadığı bölge, çözüm uzayında çok boyutlu bir hiper-küp oluşturur. Bu hiper-küpün sınırları içinde kalan eğitim verilerinin sahip olduğu sınıflar olabildiğince homojen olacak şekilde eğitim algoritması tarafından belirlenir. Bir kural, şartındaki test sayısına bağlı genelleştirilmiş ve özelleştirilmiş kural biçiminde ifade edilir. Şart ne kadar çok test içeriyorsa, o kural özelleşmiştir ve çözüm uzayında küçük bir bölgeyi tanımlamaktadır. Bu durumun aksi düşünüldüğünde şart kısmında hiç test yoksa, o kural çözüm uzayının tamamını genelleştirmiş bir çözümdür. Bağımsız öznitelik değerlerine bakmaksızın karşılaşılan her durum için aynı sınıf kararını verecektir.

Ockham'ın usturası (Occam's Razor) teorisine göre, her türlü şartın eşit olduğu ortamda ortaya konulacak iki farklı çözüm önerisinden doğruya daha yakın olanı en basit olanıdır. Dolayısıyla bir kural, eğitim verilerini doğru biçimde sınıflandıracak şekilde olabildiğince basit ve genel olabilmelidir. Bu şekilde ortaya konulacak çözüm uzayının farklı bölgelerini karşılayan kurallar ile sınıflandırma modeli tanımlanacaktır.

1.3.3.1. CN2 Algoritması

AQ ve CN2 algoritmaları, Michalski tarafından 1969 yılında önerilmiştir. Algoritmalar her adımda bir kural öğrenir. Bulunan kural ile karşılanan örnekler çıkartılıp kural öğrenme işlemi tekrarlanır. CN2 algoritması, AQ algoritması ile benzer özellikler içerdiği

için sadece CN2 algoritması açıklanmıştır. CN2 algoritmasında kuralların kalite değerini hesaplamak için bilgi kazancı ölçütü kullanılmaktadır. CN2 algoritmasında, AQ'nun kural keşfetme özelliği ile ID3 algoritmasının verideki gürültüyle baş edebilme özelliği birleştirilmiştir [52, 53].

CN2'de, kural için hangi öznitelik testinin seçileceğini belirlemek için bir strateji geliştirilmiştir. Bu stratejide, hafızada tutulan en iyi karmaşık şart ifadesi ile yeni önerilen şart karşılaştırılır. Daha iyi sonuç veren en iyi olarak tutulur. Algoritmanın kaba kodu Algoritma 1.4'te verilmiştir [52].

1.3.3.2. RIPPER Algoritması

RIPPER algoritması, 1995 yılında Cohen tarafından önerilmiştir. CN2 ve AQ algoritmalarında olduğu gibi bu algoritma da kuralları sırası ile öğrenmektedir. Algoritmanın kaba kodu Algoritma 1.5'te verilmiştir. Diğer algoritmalardan farklı olarak örneklerin hepsini öğrenmede kullanmaz. Örneklerin 2/3 kadarı ile kural öğrenirken, verinin geri kalan kısmını, kuralları budama işleminde kullanır. Kural kalitesini düşürücü şartlar, IREP algoritmasının artımlı indirgenmiş hata budama yaklaşımı kullanılarak, kural öğrenimi sırasında ortadan kaldırılmaktadır [15, 54].

Girişler: *E*: Eğitim veri kümesi.
Çıkış : *Kurallar*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: *Kurallar*: Keşfedilen kurallar kümesi.
EnİyiBileşik: eğitim veri kümesi kullanılarak bulunmuş öznitelik karşılaştırma şartları.
E': Keşfedilen *EnİyiBileşik* ile karşılanan örnekler.
C: Karşılanan örneklerde en çok geçen sınıf değeri.

```
Kurallar = { }
repeat
   EnİyiBileşik =EnİyiyiBul(E)
   E'<- KarşılananÖrnekler(E, EnİyiBileşik)
   E <- KümeyiKüçült(E, EnİyiBileşik)
   C <- MaxFrekans(E')
   Kurallar = Kurallar U {IF EnİyiBileşik THEN C}
until (E boşalıncaya VEYA EnİyiBileşik bulunamayıncaya kadar )
return Kurallar
```

Algoritma 1.4: CN2 algoritması kaba kodu.

Girişler: E: Eğitim veri kümesi.
Çıkış : *Kurallar*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: *BüyümeVerisi*: Verilerin kural öğrenimi için kullanılan 2/3'ü.
BudamaVerisi: Verilerin kural düzeltme için ayrılan 1/3'ü.
m: Sınıf sayısı.
Kurallar: Keşfedilen kurallar kümesi.

```
Kurallar = { }
E = BüyümeVerisi
repeat
  for (i = 1 ··· m) do
    Temel indirgeme ile Sınıf_i için en iyi kuralı çıkart.
    BudamaVerisi ile w(R) ve son şart çıkartılıp w(R-) kural değerlerini hesapla.
    if w(R-)<w(R) then
      Kuraldaki şartı çıkart ve yukarıdaki adımı tekrarla.
    end if
  end for
  Farklı sınıflar için en iyi w(R) değeri olan kuralları Kurallar'a ekle.
  Karşılanan örnekleri E'den çıkart.
until (E boşalıncaya kadar )
return Kurallar
```

Algoritma 1.5: RIPPER algoritması kaba kodu.

1.3.4. Meta-sezgisel Kural Öğrenme Algoritmaları

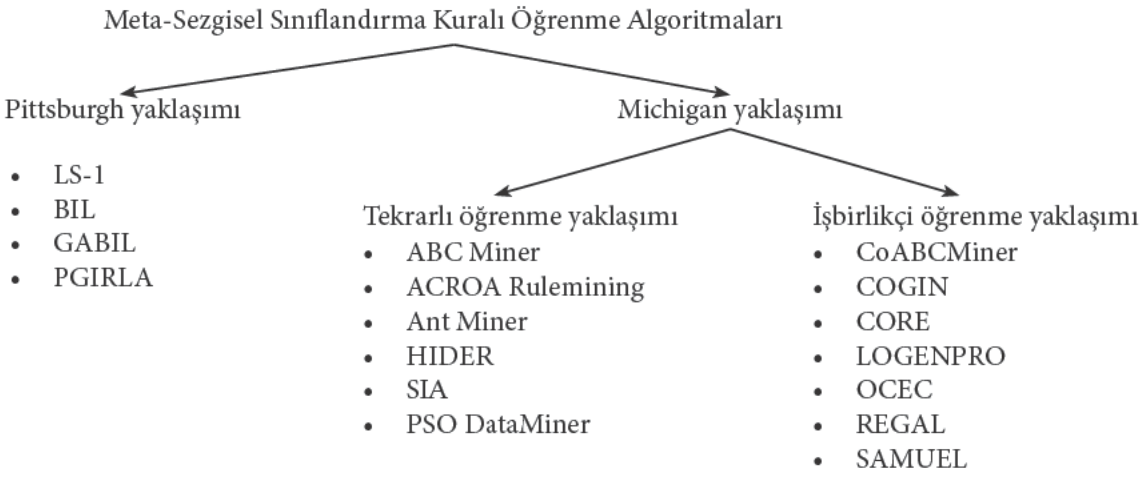
Klasik kural öğrenme algoritmalarındaki yetersiz veri karşısında genelleşmiş kural çıkartamama ve aşırı öğrenme karakteristiği, verideki gürültü nedeniyle ortaya çıkan hatalı sınıflandırma gibi dezavantajların giderilmesi amacıyla meta-sezgisel yaklaşımlar geliştirilmiştir. Klasik yaklaşımlar, eğitim verilerini istatistik hesaplamalar doğrultusunda alt kümelere ayırarak kural öğrenir. Verinin gürültülü olması veya çözüm uzayının genelini ifade edecek biçimde kapsamlı örnek içerip içermediği durumları kural çıkarım kalitesini etkilemektedir. Gürültünün etkisini gidermek amacıyla klasik algoritmalarda çeşitli budama yaklaşımları geliştirilmiş ve böylece keşfedilen kuralların kalitesi artırılmaya çalışılmıştır. Klasik kural öğrenme algoritmalarının bir diğer dezavantajı ise kullanılan aç gözlü öğrenme yaklaşımının temsil uzayının farklı bölgelerini araştırmamasından dolayı, yerel çözümlere takılma olasılığıdır. Bu problemleri giderebilmek için literatürde GA gibi evrimsel ve sürü zekası temelli meta-sezgisel

araştırma yaklaşımlarını kullanan kural öğrenme yöntemleri geliştirilmiştir. Bu yaklaşımların adaptif öğrenme, daha yüksek genelleştirme kabiliyeti ve ölçeklenebilirlik olmak üzere bazı avantajları olduğu ifade edilmiştir. GA, çaprazlama ve mutasyon gibi genetik oparatörleri temel alarak geliştirilmiş bir zeki meta-sezgisel araştırma yaklaşımıdır. İlk geliştirilen algoritmaların hepsi GA'ya dayalı olduğu için bu tür algoritmalara Genetik bazlı makineli öğrenme (Genetic based machine learning, GBML) algoritmaları da denilmiştir. Popülasyondaki kromozomlar, çözüm uzayındaki çözümleri temsil eder. Bireyler birbiriyle etkileşimde bulunarak, en iyi çözümü bulmak için evrilir. Algoritma kromozomların kalite değerini hesaplarken veri kümesi üzerinde elde ettiği doğru karşılama oranını kullanır. GA bir kez çalıştırılarak kural modeli elde edilir [31,55].

Meta-sezgisel yaklaşımlar değişik biçimlerde kural öğrenme için araştırma yapan stratejiler kullanılmaktadır. Şekil 1.5'te kural öğrenme algoritmaları verilmiştir. Literatürdeki bu tür algoritmalar Pittsburgh ve Michigan olarak adlandırılan iki temsil yaklaşımı altında incelenir [31, 55–60].

1.3.4.1. Pittsburgh Yaklaşımına Dayalı Kural Öğrenme Algoritmaları

Pittsburgh yaklaşımı ilk kez Smith tarafından Pittsburgh Üniversitesi'nde yapılan doktora tezinde önerildiği için bu ismi almıştır [134]. Pittsburgh yaklaşımı kullanan yöntemlere öğrenme sistemleri (learning system, LS) adı verilmektedir [31, 55–59]. Pittsburgh yaklaşımında popülasyondaki her bir birey sınıflandırma modelinin tamamını kodlar.



Şekil 1.5. Meta-sezgisel kural öğrenme algoritmaları.

Algoritma, sınıflandırma problemi için kısmi çözüm (tek kural) değil tam bir çözüm (kural kümesi) araştırmaktadır. Çözümler, sistem üzerinde elde edilen genel başarı ile değerlendirilir. Böylece GA araştırmayı tamamladığında ortaya koyduğu en iyi çözüm sistemin genelini modelleyen birden fazla kural içeren kural kümesi olacaktır. Bu yaklaşım klasik kural öğrenme algoritmalarında olmayan bir özelliği getirmekle beraber bazı zorluklar da içermektedir. Bu zorluklar şu şekilde ifade edilebilir [55]:

- Çözüm temsili: Çözümlerin temsil şekli kullanılan meta-sezgisel algoritmaya bağlı olarak çalışma performansını doğrudan etkilemektedir. Örneğin GA temel ikili (binary) temsil ile çözüm araştırması yapmaktadır. Araştırılmak istenen uzay sürekli değer alan sayısal bir özniteliğe sahip ise belirlenen eşik seviyeleri üzerinden değer aralıklarına indirgenerek ikili dönüşüm yapılmıştır. Yapılan bu işlem araştırma hassasiyetini düşürmektedir

- Çözüm boyutu: Meta-sezgisel algoritmaların çözümleri sabit uzunlukta olmalıdır. Halbuki bir sınıflandırma probleminin kaç kural ile modelleneceği kesin değildir. Pittsburgh yaklaşımı kullanan bir algoritmaya araştırılacak kural sayısı önceden belirtilmelidir. Bu belirsizliği gidermek için dinamik uzunlukta araştırma bireyleri geliştirilmiştir. Ancak bu kabarma (bloat) etkisi olarak adlandırılan ve önü alınamayan uzunlukta kural araştırma problemini ortaya çıkartmıştır.

- Genelleştirme: Meta-sezgisel algoritmanın yaptığı araştırmanın amacı veri kümesinin genelleştirilmiş bir modelini kural kümesi ile ortaya koymaktır. Pittsburgh yaklaşımı kullanan yaklaşımlar, çözüm uzayının farklı bölgelerini kapsayan alt çözümleri bir arada araştırdığı için bunların birbiri ile etkileşimi sınırlı kalmakta, yeterli genelleştirme yapamayabilmektedir.

- Çalışma zamanı: Pittsburgh yaklaşımları çok yavaş çalışan yaklaşımlardır. Bir bireyin geliştirilmesi ve başarısının değerlendirilmesi veri kümesinin geneli üzerinde yapılan ölçümler ile yapılabilmektedir. Bu nedenle çalışma zamanı veri kümesi boyutu ile doğru orantılı biçimde uzamaktadır.

LS-1, Pittsburgh yaklaşımını ilk geliştiren GA tabanlı makineli öğrenme yaklaşımıdır. Algoritmada kromozomlar, sınıflandırma için gerekli modelin tamamını temsil eden

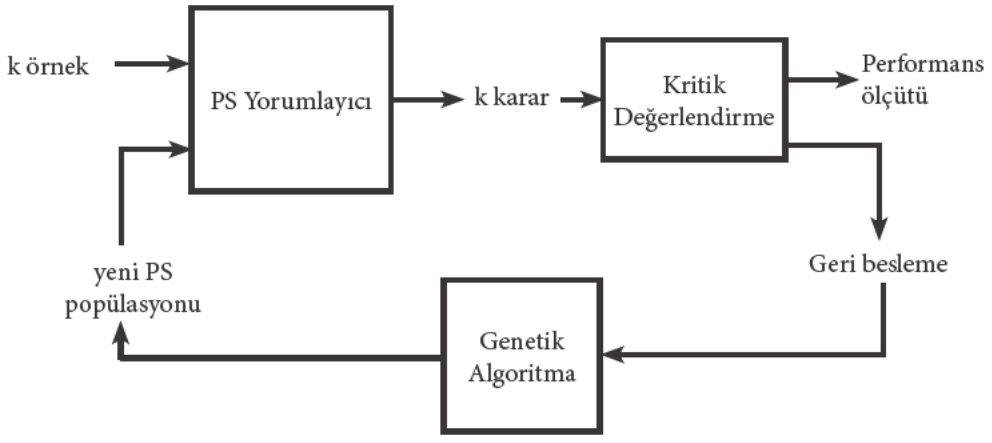
değişken uzunlukta çözümler içerir. Her bir çözüm üretim sistemi (PS) olarak adlandırılır ve rastgele üretilir. PS kümesi ile yapılan karar aşamasında yapılan değerlendirme ile sisteme geri besleme verilir. GA ile yeni çözümler geliştirilip sonraki sınıflandırmalarda kullanılır. LS-1'de yapılan işlemlerin akış şeması Şekil 1.6'da gösterilmiştir [55,57,61].

i. GIL Algoritması: GA'ya dayalı geliştirilen GIL algoritması, çözüm bireyi temsilinde Pittsburgh stratejisini kullanmıştır. Kromozomlar VL_1 mantıksal ifadeleri ile ile ayırıcı normal biçim (DNF) türündeki tanımlı sabit uzunlukta kural kümesi araştırır. Algoritma sadece kategorik öznitelikler için kural araştırabilir. Başlangıç popülasyonu üretimi için 3 farklı strateji kullanılmıştır. Birinci yaklaşımda bireylere rastgele çözümler atanır. İkinci yaklaşımda, her hangi bir örneği doğru sınıflandırabilecek şekilde rastgele doğru kurallar atanır. Üçüncü yaklaşımda önceki bir hipotez tarafından sağlanan ön bilgi ile başlangıç çözümleri belirlenir. Algoritma program döngüsü içinde genetik operatörler yardımı ile çözümleri geliştirmeye çalışır. Ortaya konan çözümler, doğruluk (*doğruluk*) ile birlikte model karmaşıklık ölçütünü (*maliyet*) belirli bir ağırlık değeri (*w3*) çarpanı ile barındıran Denklem 1.16'de verilen kalite fonksiyonu ile değerlendirilir. f algoritmanın ilerleyen adımlarında yavaşça artırılan $[0, 1]$ arası değişen bir değerdir [59].

$$Kalite(Birey_i) = doğruluk * (1 + w3 * (1 - maliyet))^f \tag{1.16}$$

ii. GABIL Algoritması:

GABIL, GA'ya dayalı ve Pittsburgh yaklaşımı kullanan bir kavram öğrenme sistemi



Şekil 1.6. LS-1 öğrenme yaklaşımı [134].

olarak geliştirilmiştir. Algoritma sadece kategorik öznitelikler içeren problemler için VL_1 mantıksal ifadeleri ile ayırıcı normal biçim (DNF) türünde kural araştırması yapmaktadır. Popülasyondaki çözümler değişken uzunlukta tanımlanabildiğinden dolayı farklı sayıda kural içeren sınıflandırma modelleri geliştirilmiştir. Popülasyon çözümlerinin kalite değerleri Denklem 1.17 ile hesaplanmıştır. Algoritmanın kaba kodu Algoritma 1.6'da verilmiştir [57].

$$Kalite(Birey_i) = [kapsama(Birey_i)]^2 = (\frac{TP}{N})^2 \tag{1.17}$$

iii. PGIRLA Algoritması:

PGIRLA, Pittsburgh yaklaşımını kullanan ve gerçek sayısal değerler ile çalışabilen GA tabanlı sınıflandırma kural öğrenme algoritmasıdır. Çözümler sabit uzunlukta tanımlanmıştır. Algoritma sayısal öznitelikleri araştırmak üzere geliştirilmiştir. Kategorik özniteliklerin araştırılabilmesi için değerlerinin sayı aralığına dönüştürülmesi gerekmektedir. Sayısal öznitelikler için karşılama aralığını belirten alt ve üst değerler araştırılır. Üst değer tutan sayının, alt değeri tutan sayıdan küçük olması halinde ilgili öznitelik şartı kuralda yer almaz. Araştırma bireylerinin kaliteleri Denklem 1.18'de

Girişler: *Örnekler*: Eğitim veri kümesi.
Çıkış : P_{eniyi}: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: $P_{eniyi}(t)$: Algoritma tarafından ortaya konulan en iyi kural kümesi.
$MaxIter$: Genetik Algoritmanın koşma sayısı.

```
t = 0
P(t) popülasyonu üret.
P(t) değerlendir.
repeat
    t = t + 1
    P(t)'yi P(t − 1) üzerinden seç.
    P(t) üzerinde çaprazlama işlemi yap.
    P(t) üzerinde mutasyon işlemi yap.
    P(t) değerlendir.
    P_eniyi(t) o ana kadar karşılaşılan en iyi çözümü seç.
until (t < MaxIter)
return P_eniyi(t)
```

Algoritma 1.6: GABIL algoritması kaba kodu [57].

verildiği gibi veri kümesi üzerinde elde ettiği doğru sınıflandırma oranı ile değerlendirilir [60, 62].

$$Kalite(Birey_i) = (\frac{TP}{N}) \tag{1.18}$$

1.3.4.2. Michigan Yaklaşımına Dayalı Tekrarlamalı Kural Öğrenme Algoritmaları

Michigan yaklaşımı adını Holland tarafından geliştirilen ilk GA tabanlı sınıflandırıcı sistem algoritmasında (CS-1) ortaya konulan araştırma bireylerinin temsil şeklinden almıştır [60]. Bu algoritmada araştırılan sınıflandırıcı sistem, *algılayıcı* (detector), *iletiler* (messages), *etkileyici* (effectors), *geri bildirim* (feedback) ve *sınıflandırıcılar* olmak üzere birbiri ile ilişkili bileşenlere sahiptir. *Algılayıcılar*, çevre koşullarını öğrenen ve ölçümleri sisteme aktaran bileşenlerdir. *İleti*, algılayıcı tarafından sisteme iletilen, ayrık bilgi paketlerine verilen isimdir. *Sınıflandırıcı* sisteme gelen iletileri bilgi işlem yöntemleri ile işleyerek atılması gereken adımları ortaya koyan mekanizmadır. *Etkileyici*, sistemin kararını gerçek dünyaya aktaran bileşendir. Sistemin verdiği karara karşılık, çevreden ödül yada ceza biçiminde alınan puanlama *geri bildirim* olarak adlandırılır. Algoritmanın araştırma bireylerinde sistemin davranışını tarif eden ikili kod biçiminde kural tanımlanmıştır. Kurallar, dolaylı yoldan aldıkları geri bildirimler ile ön plana çıkmaya çalışmaktadır. Ödüllerin dağıtımı için Kova Takımı (*Bucket Brigade*) adı verilen bir algoritma kullanılmıştır. Bu ifade itfaiye ekiplerinin insan zinciri ile kovaları elden ele iletmesinden esinlenilmiştir. Böylece sisteme verilen ödül/ceza bu kararda etkili olan bireylere paylaştırılmaktadır. Böylece aktif olmayan bireylerin, doğru bir karara olan katkısı doğrultusunda ön plana çıkması ve GA'nın başarılı sınıflandırıcılar ile yeni çözümler araştırması için kullanılmıştır [32, 63].

Pekiştirici öğrenme yöntemi kullanan bu tür algoritmalara literatürde sınıflandırıcı sistemi öğrenimi (learning classifier system) adı verilmiştir. ZCS ve XCS, pekiştirici öğrenme yapan diğer sınıflandırıcı sistemi algoritmalarına örnek verilebilir. ZCS algoritması, Holland tarafından ortaya konulan sınıflandırıcı sisteminin temel çerçevesini korumakla birlikte, kurallar için anlaşılabilirlik ve performans artışı getirmiştir. XCS algoritması ZCS algoritmalarını temel almış, farklı olarak bir tek bireylerin kalite değerlendirmesi

için doğruluk tabanlı fonksiyon kullanmıştır. Böylece anlaşılır kurallar ortaya koyan daha genel sınıflandırıcılar elde edilmiştir [32, 63–65].

Denetimli öğrenme yapan kural tabanlı sınıflandırma algoritmaları için Michigan yaklaşımı, genetik ya da sürü zekasına dayalı meta-sezgisel algoritmada kullanılan popülasyondaki bireylerin, kısmi çözüm (kural) araştırmasını ifade eder. Literatürde bu yaklaşıma dayalı bir çok meta-sezgisel kural öğrenme algoritması geliştirilmiştir. Algoritma kısmi bir çözüm vereceğinden dolayı, genel çözüm kümesini elde etmek amacıyla değişik stratejiler geliştirilmiştir. Bunlardan birincisi, klasik kural öğrenme algoritmalarında olduğu gibi algoritmanın tekrarlı biçimde bir kaç kez çalıştırılması ile kuralların sırasıyla keşfedildiği yaklaşımdır. İlk kural, eğitim veri kümesi için keşfedilen en kaliteli kuraldır. Sonraki kural araştırılmaya başlamadan önce, doğru tahmin edilen eğitim örnekleri çıkartılır. İndirgenen veri kümesi için en yüksek kaliteye sahip başka bir kural çıkartılmaya çalışılır. Bu süreç veri kümesinde örnek kalmayıncaya kadar sürdürülür. Aşağıdaki alt bölümde, denetimli öğrenme yapan GA'ya dayalı *SIA*, Evrimsel Algoritmaya (EA) dayalı *HIDER*, ACO'ya dayalı *Ant-Miner* ve PSO'ya dayalı *PSO-DataMiner* algoritmaları kısaca açıklanacaktır.

i. SIA Algoritması:

SIA algoritması GA temelli bir kural öğrenme algoritmasıdır. Sınıflandırma modelini temsil eden kuralları sırasıyla bulmaktadır. Algoritma, Genetik operatörler yardımıyla kuralları genelleştirir. Kuralların kalite değerleri Denklem 1.19 ile hesaplanır. α; sıfırdan büyük katsayı, β; 0, 0.001, -0.001 değerlerinden birini alan katsayı, c; R kuralı tarafından doğru sınıflandırılmış örneklerin toplam ağırlığı, nc; R'nin sınıflandıramadığı örneklerin toplam ağırlığı, g R'nin genellik ölçütü, c_{size}; C_i sınıfına sahip örneklerin toplam ağırlığıdır. Algoritmanın kaba kodu Algoritma 1.7'de verilmiştir [66].

$$Kalite(R) = C_q(R) = \frac{c - \alpha nc + \beta g}{c_{size}} \tag{1.19}$$

ii. HIDER Algoritması:

Hider algoritması, Evrimsel Algoritma (EA) temelli tekrarlamalı biçimde çalışan bir kural öğrenme algoritmasıdır. Algoritma veri kümesindeki hem kategorik hem de sayısal

Girişler: E: Eğitim veri kümesi.
Çıkış : R: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: ex: C_i sınıfına ait daha önce kapsanmamış bir eğitim örneği.
$prob$: GA işlem seçme operatörü için olasılık değeri.
P: GA çözüm popülasyonu.
R^*: GA tarafından ortaya konulan en iyi çözüm.

```
R = { }
repeat
  E içinden rastgele bir ex seç.
  Seçilen örnek (ex) ile örtüşen özelleşmiş bir kural (R_init) tanımla.
  //GA adımları (genelleşmiş en iyi R* kuralı geliştir.)
  while (i < Nb_max) do
    P = P ∪ R_init
    prob için rastgele değer ata.
    if (prob < 0.1) then
      R_init için genelleştirme yap, R' üzerinde ekleme operatörü çalıştır.
    else if (prob < 0.9) then
      P içinden rastgele R kuralı seç, genelleştirme yap.
      R' için R ile R' arasında aç gözlü seçim yap, ekleme operatörü çalıştır.
    else
      P içinden R1, R2 rastgele iki kural seç, uniform çaprazlama yap.
      R'1, R'2 ekleme operatörü çalıştır.
    end if
    R* seç.
    if (C_q(R') < C_q(R*)) then
      i = i + 1
    else
      i = 1
    end if
  end while
  R* ile karşılanan örnekleri eşleştirildi işaretle.
  R*'yi R kümesine ekle.
until (|C_i| > 0
return R
```

Algoritma 1.7: SIA algoritması kaba kodu.

özniteliklere uygun kural araştırması yapabilmektedir. Kuralda sayısal öznitelik için alt ve üst değer arası bir aralık araştırılır. Kategorik öznitelik için ikili (binary) temsil ile verilen değer kümesinin her bir elemanı için olup olmaması durumu araştırılır. Algoritma, sınıflandırma işleminde ilk kuraldan son kurala doğru çalıştırılan hiyerarşik kurallar kümesi keşfeder. Çözüm bireyleri, doğru ve yanlış sınıflandırmaların ayrıştırıldığı, Denklem 1.20 ile değerlendirilir. $CE(\varphi)$; örtüşen örneklerden farklı sınıflı örnekleri ifade

eden sınıf hatası, $G(\varphi)$; kural tarafından doğru sınıflandırılan örnek sayısı, $kapsama(\varphi)$, kuralın çözüm uzayını kapsama oranı, N ise veri kümesindeki eğitim örneklerinin sayısıdır. Algoritmanın kaba kodu Algoritma 1.8'de verilmiştir [67, 68].

$$Kalite(\varphi) = 2 * (N - CE(\varphi)) + G(\varphi) + kapsama(\varphi) \tag{1.20}$$

iii. Ant-Miner Algoritması:

ACO karıncaların sürü zekası içinde birlikte hareket etmelerini örnek alan bir optimizasyon algoritmasıdır. Bir karınca, diğerlerinin elde ettiği tecrübeden faydalanarak yiyecek ile yuva arasındaki kısa olan yolu tercih etmektedir. Bunu geçtikleri yola

Girişler: E: Eğitim veri kümesi.
Çıkış : R: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: n: Eğitim örneği sayısı.
r: Evrimsel algoritma ile keşfedilen en iyi kural.
epf: Örnek budama katsayısı.
$iterasyonSay$: Evrimsel algoritmanın tekrar sayısı.

```
R = { }
n = |E|
while (|E| > n * epf) do
  //r = EvolAlg(E) algoritma çalıştır.
  i = 0
  P, başlangıç popülasyonu hazırla.
  P yi değerlendir.
  while (i < iterasyonSay) do
    for (j = 1 ··· |P_{i-1}|) do
      x̄ = Seç(P_{i-1}, i, j)
      P_i = Çaprazlama(x̄, P_{i-1}, i, j)
    end for
    Değerlendir(P_i, i)
    i = i + 1
    r'yi seç.
  end while
  R = R ⊕ {r}
  E = E − {e ∈ E|e ⊆ △_r}
end while
return R
```

Algoritma 1.8: HIDER algoritması kaba kodu.

bıraktıkları feremon adlı maddeyi takip ederek yapmaktadırlar. Kısa olan yol üzerinde uzun yollara oranla daha fazla feremon maddesi birikmekte böylece bir süre sonra kısa olan yol daha çok tercih edilmektedir [16].

Ant-Miner algoritması, ACO algoritması kullanarak sınıflandırma problemi için kural keşfi yapmaktadır. Algoritmanın kaba kodu Algoritma 1.9'da verilmiştir. Sınıflandırma işlemi ayrık değerli özniteliklere sahip veri kümelerine uygulanabilmektedir. Kuralların kalite değerleri Denklem 1.15 ile hesaplanmıştır [69].

iv. PSO DataMiner Algoritması:

PSO birçok parçacığın (balık, kuş sürüsü) birlikte hareketi sırasında en iyi yiyecek kaynağını araştırmak için yaptıkları etkileşimleri temel alarak geliştirilmiş bir

Girişler: *Örnekler*: Eğitim veri kümesi.
MaxÖrnek: Veri kümesinde göz ardı edilecek max. örnek sayısı.
Çıkış : *Kurallar*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: *KSay*: Karınca sayısı.
YaklaşımKuralSay: Kural yaklaşımı için kabul edilen sayı.
R_t: R_t karıncası tarafından ortaya konulan kural.

Kurallar = { }
while ($|Örnekler| > MaxÖrnek$) **do**
$t = 1$
$j = 1$
Bütün olasılıklara aynı oranda feremon miktarı ata.
repeat
$Karınca_t$'yı boş kural(R_t) ile başlat, R_t'ye bir terim ekleyerek geliştir.
R_t için sadeleştirme işlemi yap.
$Karınca_t$ tarafından kullanılan terimler için feremon güncelle.
if (R_t = R_{t-1}) **then**
$j = j + 1$
else
$j = 1$
end if
$t = t + 1$
until ($t \geq KSay \vee j \geq YaklaşımKuralSay$)
R_{eniyi} kuralı seç ve $Kurallar$'a ekle
R_{eniyi} ile karşılanan örnekleri eğitim kümesinden çıkart.
end while
return Kurallar

Algoritma 1.9: Ant-Miner algoritması kaba kodu.

optimizasyon algoritmasıdır. Her bir parçacık başlangıç hız vektörleri doğrultusunda hareket ederken daha iyi çözüm sunan komşu parçacık ile etkileşime girerek kendi hız ve yönünü günceller. Her bir bireyin hız vektörü, kendi deneysel bilgisini, bunun yanında sosyal olarak komşularından elde ettiği bilgiyi yansıtır [16]. PSO DataMiner algoritması, PSO algoritmasına dayalı geliştirilmiş bir tekrarlamalı kural öğrenme algoritmasıdır. Algoritmanın kaba kodu Algoritma 1.10'da verilmiştir. Parçacıkların temsil ettiği kuralların kalite değerleri Denklem 1.15 ile hesaplanmıştır [70].

1.3.4.3. Michigan Yaklaşımına Dayalı İşbirlikçi Kural Öğrenme Algoritmaları

Michigan yaklaşımına dayalı ikinci grup denetimli kural öğrenme algoritmaları işbirlikçi kural öğrenme algoritmalarıdır. Bu tür algoritmalar her biri ayrı kural tanımlayan araştırma bireyleri arasında işbirliği stratejisi geliştirerek, farklı kuralları birlikte keşfeder. Michigan stratejisindeki gibi çözümleri tek kural biçiminde kodlamasından dolayı ve Pittsburgh stratejisindeki gibi çalışma sonunda kuralların hepsini bir

Girişler: *Örnekler*: Eğitim veri kümesi.
MaxÖrnek: Veri kümesinde göz ardı edilecek max. örnek sayısı.
Çıkış : *Kurallar*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: $Kural_{eniyi}$: PSO çalışması sonucu bulunan eğitim kümesini en iyi karşılayan kural.

Kurallar = { }
while $(|\ddot{O}rnekler| > Max\ddot{O}rnek) \wedge (|\ddot{O}rnekler_{sınıf}| > 1)$ **do**
En fazla örnek içeren sınıfı seç
Parçacıklara, rastgele başlangıç hız ve konum değerleri ata.
repeat
Parçacıkların konumlarını kalite fonksiyonu ile değerlendir.
En kaliteli parçacığı seç ($Kural_{eniyi}$).
Parçacıkların hızlarını en iyi parçacığı kullanarak güncelle.
Parçacıkların konumlarını güncelle.
$i = i + 1$
until (i < iterasyon Sayısı)
$Kural_{eniyi}$ gereksiz öznitelikler varsa temizle.
$Kural_{eniyi}$ ile karşılanan örnekleri eğitim kümesinden çıkart.
$Kural_{eniyi}$'yi $Kurallar$'a ekle
end while
return Kurallar

Algoritma 1.10: PSO DataMiner algoritması kaba kodu.

arada keşfetmesinden dolayı literatürde hibrit kural öğrenme sistemleri olarak da adlandırılmıştır. İşbirliği stratejisi sınıflandırma modelini bir arada tanımlaması için algoritmanın farklı araştırma bireylerinin yaptıkları yardımlaşmayı ifade etmektedir. Bu yardımlaşma doğrultusunda araştırma bireyleri daha kaliteli ve genel kurallar biçiminde geliştirilir. Algoritma, araştırma bireylerinin kural kümesinde yer almak üzere daha sonra birbiri ile yaptığı yarışma stratejisi de barındırır. Böylece daha yüksek doğruluklu sınıflandırma modelleri elde edilir [46, 60, 71–73].

i. COGIN Algoritması:

COGIN, GA tabanlı Michigan stratejisinin sabit uzunluk temsili ile Pittsburgh stratejisinin öğrenme yaklaşımını bir arada kullanarak geliştirilmiş bir kural öğrenme algoritmasıdır. Sayısal öznitelikleri desteklememektedir ve çözüm bireylerinde ikili temsil kullanılmıştır. Başlangıç aşamasında, çözümler örnekleri kapsayacak biçimde rastgele tanımlanır. Tanımlı kurallar kalitelerinin değerlendirmesi ile birlikte yeni kurallar rastgele türetilir. Aday yeni kurallar değerlendirilir ve kalite değerleri hesaplanır. Bir önceki adımda mevcut kurallar ile yeni aday kurallar arasında yarışma yapılır ve hiç bir örneği karşılamayan kurallar elenir. Bundan dolayı algoritmanın araştırma popülasyonu büyüklüğü dinamik yapıdadır. Araştırmanın sonunda popülasyonda yer alan bireylerin tamamı kural kümesi olarak kullanılır [71].

ii. LOGENPRO Algoritması:

Makineli öğrenme yöntemleri geliştirilirken tümevarım, tümdengelim, genetik ve ilişkisel yaklaşımlara dayalı yöntemler geliştirilmiştir. Tümevarım, özel bir veriden başlayıp genelleşmiş çıkarımlara ulaşılması işlemine denilmektedir. Tümevarımsal mantık programlama (ILP) günümüzde biyoinformatik ve doğal dil işleme uygulamalarında kullanılmaktadır [36]. U evrensel küme olmak üzere, C kavramı, U üzerinde elde edilmiş gözlemler alt kümesi biçiminde ifade edilir. Tümevarımsal öğrenme, çeşitli hedef kavramlara ait tanımlamaların pozitif/negatif örnekler ile bulunmasıdır. E^+ ve E^-, C üzerinde verilen doğru ve yanlış örnek verilerdir. Eğitim sonunda tümevarım yolu ile elde edilen H doğru hipotezi öğrenilen programı ortaya koyar. ILP kavramlarının veri kümesi indirgemesinde kullanılan kavramlar ile karşılaştırılması Tablo 1.2'de verilmiştir [74, 75].

Logenpro Genetik Programlama (GP) ve tümevarımsal mantık programlamanın (ILP) birlikte kullanılması ile geliştirilmiş bir öğrenme yaklaşımıdır. Veriden sembolik fonksiyonel ifade (S-expression) çıkarımı, karar ağaçları ve kural kümesi öğrenimi için Logenpro kullanılmıştır. Foil ve Progol adıyla tümevarım yaklaşımına dayalı başka mantık programlama araçları da geliştirilmiştir. Logenpro mantık gramerini temel alan temsil biçimi kullanmıştır. Mantık grameri, bağlam-bağımsız gramerinin (CFG) genelleştirilmiş biçimidir. İfadeler değişken, fonksiyon veya bir sabit değer olabilen terimlerden ve parametrelerden oluşur. Parametre olarak yine her hangi bir terim kullanılabilir. Böylece iç içe ifadeler tanımlanır. Değişken soru işaretini (?) takip eden harfler ve rakamlarla tanımlanır. Fonksiyon parantez ile verilen bir demet parametre ile yazılır. Sabit ise parametresiz bir fonksiyondur. Terminal simgeleri köşeli parantezler ile tanımlanır. $a - b$ biçiminde bir işlem ifadesi, *[(- ?a ?b)]* şeklinde yazılır. Her bir gramer kuralı sonunda nokta işareti yer alır. Mantık grameri için örnek Tablo 1.3'te verilmiştir. Gramer kurallarının sağ kısımda yer alan ifadeler mantık hedeflerini ve simgeleri içermektedir. Hedefler, verilen kuralın geçerli olabilmesi için mantıksal önerme şart ifadeleridir. Tabloda verilen *member(?x, [W, Z])*, x değişkeninin $[W, Z]$ aralığında değer alıp almadığını kontrol etmektedir.

Eğitimine başlamadan önce keşfedilecek kural biçimi, probleme ait öznitelikler ve alabileceği değer türleri mantık gramerinde tanımlanmalıdır. Daha sonra gramere uygun GP ile çözümler araştırılır. Tablo 1.4'te Logenpro algoritmasının kural öğrenimi için yapılacak araştırmasında kullanılacak 3 giriş özniteliği olan bir problem için gerekli kurallar verilmiştir. Birinci satırda koşul ile sonuç arasında ilişkiyi tanımlayan kural verilmiştir. Sonraki satırlarda sırasıyla koşul bileşenleri ve sonuç bileşeni ifade edilmiştir.

Tablo 1.2. Veri kümesi indirgemesi ile tümevarımsal mantık programlamanın karşılaştırması.

Veri Kümesi İndirgeme	Mantık Programlama
Bağıntı (*p*)	Yüklem sembolü (*p*)
Öznitelik	Yüklem bileşeni
Sıralı liste $\langle a_1, \ldots, a_n \rangle$	Temel gerçek $p(a_1, \ldots, a_n)$
$p-$ Bağıntısı	$p-$ Yüklemi
Tablo, kayıt kümesi	Temel gerçek kümesi
q Bağıntısı	q Yüklemi
Kayıtlar	Kurallar kümesi

Tablo 1.3. Mantık grameri örneği.

1:	basla	->	[(*], exp(W), exp(W), exp(W), [)] .
2:	basla	->	{member(?x, [W, Z])}, [(*], exp-1(?x), exp-1(?x), exp-1(?x), [)].
3:	basla	->	{member(?x, [W, Z])1} [(+], exp-1(?x), exp-1(?x), exp-1(?x), [)].
4:	exp(?x)	->	[(/ ?x 1.5)].
5:	exp-1(?x)	->	{random(1,2,?y)}, [(/ ?x ?y)] .
6:	exp-1(?x)	->	{random(3,4,?y)}, [(- ?x ?y)] .
7:	exp-1(W)	->	[(+ (- w 11) 12)].

Her bir terimde yer alan alt terimler sonraki satırlarda tanımlanmıştır. En alt satırlarda ise değişkenlerin alabileceği değer aralıkları verilmiştir [74, 75].

iii. SAMUEL Algoritması:

SAMUEL probleme özgü modül, performans modülü ve öğrenme modülü olmak üzere üç kısımda tanımlanmış GA tabanlı bir yarışmalı öğrenme yaklaşımıdır (Şekil 1.7). GA tabanlı öğrenme mekanizması LS-1 sistemini temel almıştır. Popülasyon çözümleri LS-1'deki ikili düzendeki kodlama yerine yüksek seviyeli kural dili olarak adlandırılan *Eğer-ise* kuralları ile kodlanmıştır. Öğrenme sürecinde aynı durumu doğru biçimde karşılayan kurallara *Gelir Paylaşma Planı (PSP)* adı verilen bir yaklaşım ile kredi dağıtımı yapılmıştır [76].

iv. OCEC Algoritması:

OCEC algoritması, EA'ya dayalı aşağıdan yukarı doğru araştırma yaparak kural kümesi elde eden bir kural öğrenme algoritmasıdır. Sadece kategorik öznitelikler araştırabilir. Her bir sınıf için ayrı popülasyon geliştirmektedir. OCEC algoritması, eğitim veri kümesini öncelikle alt gruplara ayrıştırır. Örneklerin benzerlikleri doğrultusunda farklı organizasyonlar tanımlar. Meta-sezgisel algoritma organizasyon üyeleri arasında genelleştirmeyi sağlamak üzere çalıştırılır. Kurallar, evrimsel çevresel araştırma süreci tamamlandıktan sonra organizasyonlardan çıkartılır. Organizasyonların kalitelerinin değerlendirilmesi için organizasyondaki üye sayısı ve her bir kural için keşfedilmiş öznitelik sayısı dikkate alınır. Aynı zamanda keşfedileek bir kuralda her türlü özniteliğin değil, sadece yüksek değerli olan özniteliklerin olması istendiğinden dolayı, her bir A

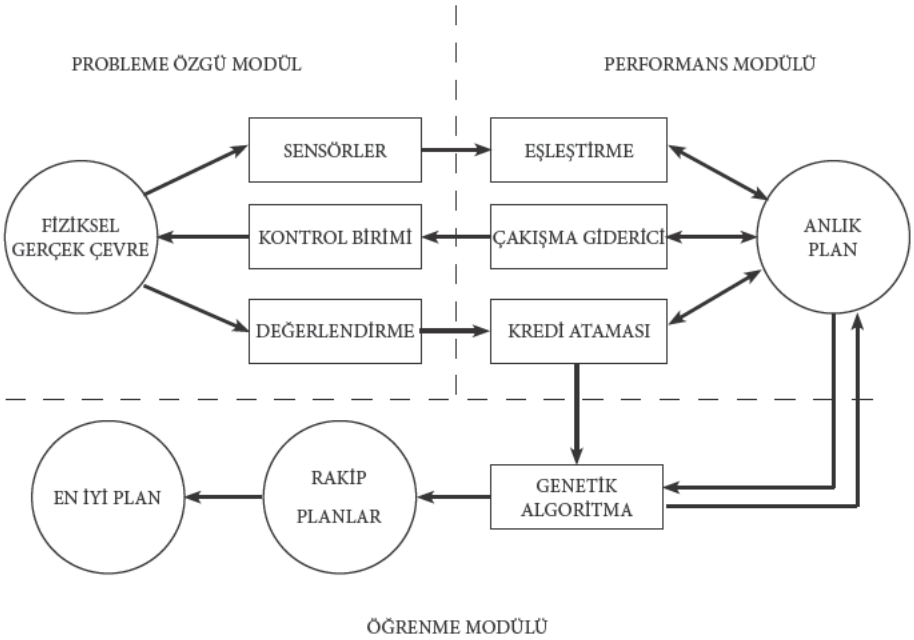
Tablo 1.4. Kural gösterimi için mantık grameri örneği.

1:	basla	→	[if], kosul, [, then], sonuc, [.].
2:	kosul	→	nit1,[and], nit2,[and], nit3 .
3:	nit1	→	[herhangi] .
4:	nit1	→	nit1_secici .
5:	nit2	→	[herhangi] .
6:	nit2	→	nit2_secici .
7:	nit3	→	[herhangi] .
8:	nit3	→	nit3_secici .
9:	nit1_secici	→	[nit1],[=],sbt1.
10:	nit2_secici	→	[nit2],[is],kategori1.
11:	nit2_secici	→	[nit2],[arasında],sbt2,sbt3.
12:	nit3_secici	→	[nit3],operator,terim.
13:	operator	→	[=].
14:	operator	→	[$\neq$].
15:	operator	→	[<=].
16:	operator	→	[>=].
17:	operator	→	[>].
18:	operator	→	[<].
19:	terim	→	nit2 .
20:	terim	→	sbt3 .
21:	sonuc	→	nit4_secici .
22:	nit4_secici	→	[nit4],[=],bool .
23:	bool	→	{deger(?a,[Dogru,Yanlış])},[?a] .
24:	kategori1	→	{deger(?a,[az,orta,çok])},[?a] .
25:	sbt1	→	{deger(?a,[0,1,2])},[?a] .
26:	sbt2	→	{rastgeledeger(0,200,?a)},[?a] .
27:	sbt3	→	{rastgeledeger(0,200,?a)},[?a] .

özniteliği için öznitelik önem hesaplaması (S_A) yapılır. Algoritmanın kaba kodu 1.11'de verilmiştir [72].

v. REGAL Algoritması:

REGAL, GA'ya dayalı çok-modlu (multi-modal) kavram öğrenme yaklaşımı olarak geliştirilmiştir. Kurallar sözel kurallar tanımlayan diğer algoritmaların aksine, VL_2 ile VL_{21} arasında yer alan birinci derece mantıksal dil (£) ile tanımlanmıştır. Michigan ve Pittsburgh yaklaşımların karışımı bir evrimsel metodoloji kullanır. Algoritmanın durmasıyla, tam çözümü ortaya koyan ve popülasyondaki bireylerin bir alt kümesi çözüm kümesi olarak verilir. GA'nın sahip olduğu seçim ve değiştirme operatörlerini REGAL kendi yaklaşımına göre değiştirmiştir. Evrensel seçilme hakkı (Universal Suffrage



Şekil 1.7. SAMUEL Algoritması Modülleri [76].

Selection) adı verilen yeni bir seçme operatörü kullanılmıştır. Bu operatör, popülasyonun bazı bireylerin denge durumuna asimtotik biçimde yakınsamasını sağlar [73].

vi. CORE Algoritması:

CORE algoritması, Tan ve arkadaşları tarafından geliştirilmiş GA tabanlı kooperatif kural öğrenme algoritmasıdır. Algoritmanın kaba kodu Algoritma 1.12'de verilmiştir. Kromozomları, gerçek sayılar ile tanımlanmış tek kural temsil eder. Algoritma iki aşamalı olarak araştırma gerçekleştirir. Birinci aşamasında en iyi kurallar araştırılır. İkinci aşamasında en iyi kural kümesi araştırılır. Kurallar kendi başlarına geliştirilip GA sonlandırıldıktan sonra, popülasyon içindeki çözümler, Pittsburgh algoritmasında olduğu gibi farklı kombinasyonlar ile veri kümesine en iyi çözümü sunabilmek maksadıyla bir arada değerlendirilir ve en iyi kural kümesi araştırılır. Popülasyondaki anlamlı kuralları belirlemek amacıyla ödüllü yarışma (token competition) adı verilen ilave bir yaklaşım geliştirilmiştir. Ödüllü yarışma içinde, eğitim örnekleri sırasıyla her bir kural ile sınıflandırılmaya çalışılır. Farklı kurallar aynı örneği sınıflandırırsa, ödül, kalitesi daha yüksek olan kurala verilir [46].

Popülasyon içinde çeşitliliği korumak için ise yeniden üretim mekanizması geliştirilmiştir. Kalitesi belirli bir eşik değerden düşük kalan kromozomlar yerine

Girişler: $example$: Eğitim veri kümesi.
Çıkış : *R*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: m: Sınıf sayısı.
$c_1, c_2, \cdots, c_m$: Sınıflar.
e_i: i. örneğin sınıf etiketi.

```
for (i = 1 ··· |example|) do
  if (e_i c_j sınıfına ait ise) then
    e_i'yi P_j^0 popülasyonuna ekle.
  end if
  t = 0
  while (durdurma kriteri sağlanıncaya kadar) do
    j = 1
    while (j ≤ m) do
      while (|P_j^t|_organizasyonSay > 1) do
        P_j^t üzerinden org_p1 ve org_p2 rastgele organizasyon seç.
        3 evrimsel operatörden birini rastgele seç.
        org_p1 ile org_p2 arasında operatörü uygula.
        org_c1 ile org_c2 temelinde öznitelik önemini güncelle.
        org_c1 ile org_c2 kalite değerlerini hesapla.
        org_c1, org_c2, org_p1 ve org_p2 arasında seçim yap.
        org_p1 ve org_p2 değerlerini P_j^t üzerinden sil.
      end while
      j = j + 1
      P_j^t üzerinde kalan organizasyonları P_j^{t+1} aktar.
    end while
    t = t + 1
  end while
  Bütün popülasyonlardan kuralları(R) çıkart.
end for
return R
```

Algoritma 1.11: OCEC algoritması kaba kodu.

yeniden rastgele kromozomlar tanımlanır. Aday havuzu içinde ödüllü yarışmada başarılı olmuş kromozomlar ile ana popülasyonun içinden rastgele seçilmiş $1/10$ oranındaki kromozom ile alt-popülasyonlar tanımlanır. Algoritmanın keşfedebileceği maksimum kural sayısı kadar alt-popülasyon tanımlanır. Bütün alt-popülasyonlar eşit sayıda kural içerecek şekilde tanımlanır. Alt-popülasyonlar, Pittsburgh yaklaşımında olduğu gibi sabit kural sayısı uzunluğunda tanımlanmış kromozomlar olarak değerlendirilir ve bu çözümler ile yeni bir GA çalıştırılır. Kural kümesi araştırması yapan GA çalışmasında, tekrarlı gereksiz kurallar çıkartılmasını önlemek amacıyla sadece mutasyon operatörü

Girişler: $example$: Eğitim veri kümesi.
Çıkış : *R*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Veri: $GeneMap$: Her bir özniteliğin alabileceği değer aralığını tanımlayan referans tablosu.

```
Eğitim örneklerinden GeneMap hesapla.
GeneMap'e dayalı ana popülasyonu başlat.
her bir kromozomun kalitesini hesapla.
repeat
    Çaprazlama havuzu için gerekli bireyleri turnuva seçimi ile ana popülasyondan seç.
    Yeni bireyler için çaprazlama uygula.
    Yeni bireyler için mutasyon uygula.
    Kromozomların kalitesini değerlendir.
    Yeni çözümler arasında ödüllü yarışma gerçekleştir.
    Yeniden üretim olasılığı ile yeniden üretim işlemi uygula.
    Aday havuzu ve ana popülasyondan kromozomları seçerek alt-popülasyon tanımla.
until (durdurma kriteri sağlanıncaya kadar)
return R
```

Algoritma 1.12: CORE algoritması kaba kodu.

kullanılmıştır. Değerlendirmenin sonunda, her bir alt-popülasyon kendi en iyi aday kural kümesini verecektir. Sınıflandırma başarısı ile değerlendirilirek en iyi kural kümesi son sınıflandırma modeli olarak ortaya konulur [46].

2. BÖLÜM

ABCMiner: İTERATİF YAKLAŞIM İLE ABC TABANLI SINIFLANDIRMA KURALLARI KEŞFİ ALGORİTMASI

Bu bölümde, ilk önce arı kolonilerinin yiyecek arama davranışını temel alarak geliştirilmiş Yapay Arı Koloni (ABC) algoritması açıklanmıştır. Daha sonra kural tabanlı sınıflandırma modeli öğrenimi için geliştirilen Yapay Arı Koloni Algoritmasına (ABC) dayalı bir iteratif kural keşfi algoritması (ABCMiner) açıklanmaktadır.

2.1. Yapay Arı Koloni Algoritması (ABC)

Belirli sınırlamalar çerçevesindeki sistemi iyileştirmek üzere bilinmeyen parametre değerlerinin bulunması problemine optimizasyon problemi denir. Muhtemel tercihler arasından birinin seçilmesi kararına ihtiyaç duyulan Mühendislik, Ekonomi, Tıp, Sosyal, Endüstriyel vb. bir çok alanda bu tür problemlerle karşı karşıya kalınmaktadır. En düşük yakıt maliyetine sahip yüksek performanslı bir otomobil geliştirilmek istenmesi, tasarım (optimizasyon) problemine örnek olarak verilebilir. Sayısal filtre tasarımı, mikrodalga anten tasarımı, iş çizelgeleme problemi ve gezgin satıcı problemi bu tip problemlere verilebilecek örneklerdir [16].

Çok parametreli tasarım problemleri için mümkün olabilecek çözümler arasından en uygun parametre değerlerinin bulunması için literatürde çeşitli yöntemler ortaya konulmuştur. Bu problemler, çeşitli şartlardan dolayı oldukça zor problemler olabilir. Klasik yaklaşımların türeve dayalı olması, geliştirilen çözümlerin başlangıç koşullarına bağlılığı ve çözüm uzayının sürekliliği gibi nedenlerden dolayı bu problemlerin çözümünde klasik yöntemlerin yetersiz kaldığı durumlarda daha başarılı sonuçlar elde etmek amacıyla evrimsel ve sürü zekasına dayalı meta-sezgisel algoritmalar geliştirilmiştir. Bu algoritmalar, parametre değerlerinin farklı kombinasyonlarını içeren

çözüm populasyonunu bir arada değerlendirir ve iyileştirerek en iyi çözümü bulmaya çalışır. GA, TS, SA, ACO, AI, DE, PSO ve ABC gibi literatürde bir çok meta-sezgisel algoritma ve türevleri geliştirilmiştir. Bunlardan TS ve SA komşuluk tabanlı araştırma yapan ve bir çözüm üzerinden uzayı araştıran algoritmalardır. Diğer algoritmalar ise tek bir çözüm üzerinden değil bir çözüm kümesi üzerinden araştırma yapan popülasyon tabanlı algoritmalardır [16].

Bir popülasyon tabanlı algoritma grubu olan sürü zekası temelli algoritmalar rastgele bir başlangıç yapar ve çözüm önerisinin başarısını amaç fonksiyonunu kullanarak değerlendirir ve amaç fonksiyonunu en küçük/büyük yapacak şekilde en doğru çözümü araştırır. Sürü zekasının iki temel özelliği vardır [21]. Bunlardan birincisi, her birey bir danışman olmaksızın kendi kendine organize olabilmelidir. Araştırma bireylerinin kendi kendine organize olması pozitif geri besleme, negatif geri besleme, rastlantısal hareketler ve çoklu etkileşim olmak üzere 4 temel araştırma prensibine dayanmaktadır. İkincisi, sürü içindeki bireyler arasında bir iş bölümü yapılmalıdır [16, 21].

ABC, doğadaki bal arılarının bal yapmak için farklı yiyecek kaynaklarından nektar toplamak amacıyla işbirliği içinde sergiledikleri zeki davranışı basit biçimde modelleyen sürü temelli bir yapay zeka algoritmasıdır. ABC, bir çok alanda farklı tasarım problemlerinin çözümünde başarıyla uygulanmıştır. Ayrıca ABC, Scholarpedia'da hakkında makale yayınlanmış Türk Bilim Adamları tarafından geliştirilmiş ilk algoritma olmuştur [21, 78, 79]. ABC ile ilgili yapılmış çalışmaları bir arada sunan detaylı bir özet [79]'de bulunabilir.

ABC algoritmasında işçi arılar, görevli ve görevsiz olmak üzere iki ana gruba ayrılarak temel araştırma süreçlerini gerçekleştirir. Görevli arı, bir yiyecek kaynağını saptayarak hafızasında tutan ve buradan kovana sürekli nektar taşıyan işçi arıdır. Görevli arı, kovandaki diğer arılara kendi yiyecek kaynağı hakkında bilgileri (yiyecek kaynağının yönü, mesafesi, besin kalitesi vb.), sallanma dansı denilen bir iletişim tekniği ile aktarır. Sallanma, titreme ve dairesel biçimlerde olabilen arı dansı, yiyecek kaynağının kovana olan uzaklığını, kalitesini ve yönünü bildirir.

Görevsiz arılar gözetleyici arılar ve kaşif arı olmak üzere ikiye ayrılır. Gözetleyici bir arı kovan içinde görevli arıların buldukları kaynaklarla ilgili bilgi veren özel hareketlerini

izler. Görevli arıların verdikleri bilgilere göre kendi yiyecek kaynaklarını belirlerler. Kaşif arı, daha önce hiç ziyaret edilmemiş yeni yiyecek kaynakları bulmak amacıyla rastgele çözümler geliştirir. Görevli arılar, hafızalarındaki yiyecek kaynaklarının nektarı tükendiğinde ya da verimi düştüğünde eski yiyecek kaynaklarını terk eder, görevsiz kaşif arıya dönüşür ve yeni yerler araştırır.

Sürünün kendi kendine organize olabilmesi için gerekli dört araştırma prensibi ABC algoritmasındaki arılar arasında vardır. Bunlardan birincisi kaynaklar üzerinde pozitif geri besleme etkisinin olmasıdır. Kalitesi daha yüksek bir yiyecek kaynağının daha fazla gözetleyici arı tarafından tercih edilmesi pozitif geri beslemeye örnektir. İkincisi, negatif geri beslemedir. Arılar tükenen yiyecek kaynaklarını bırakıp, bunun yerine yeni kaynaklar araştırır ve daha kaliteli yiyecek kaynaklarını tercih eder. Üçüncüsü, arıların sahip olduğu yiyecek kaynaklarındaki raslantısal dalgalanmadır. Kovandaki kaşif arılar eski verilere bağlı kalmadan sürekli farklı yiyecek kaynaklarını araştırır. Böylece arıların aynı yiyecek kaynaklarına takılıp kalmasının önüne geçilir. Davranışlardan sonuncusu, arılar arasındaki çoklu etkileşimdir. Gözetleyici arılar görevli arıların hepsiyle de dans izleme esnasında iletişime geçebilir.

İşçi arılar, olabilecek en yüksek kârlılıktaki yiyecek kaynaklarını tercih ederler. Bundan dolayı yiyecek kaynağının kovana olan yakınlığı, besinin kalitesi gibi çeşitli parametreler yiyecek kaynağının arı tarafından seçilmesinde belirleyicidir. Bu kriterler doğrultusunda arı kolonisi sürekli gelişim içindedir ve en kârlı biçimde kaliteli nektarları kovana taşıma arayışını sürdürür.

Yukarıda bahsedilen temel kavramlar kullanılarak ABC algoritmasının kaba kodu Algoritma 2.1 ile tanımlanabilir. İlk aşamada arılar araştırma uzayına düzgün biçimde dağılır (2. Adım). Arıların başlangıç yiyecek kaynaklarının kaliteleri, amaç fonksiyonu ile ölçülür (3. Adım). Algoritma maksimum çevrim sayısı (MCN) kadar işlenecek üç temel evreye sahiptir. Bunlar sırasıyla görevli arılar aşaması (5. Adım), gözetleyici arılar aşaması (6. Adım) ve kaşif arı aşamasıdır (8. Adım). Maksimum çevrim sayısı tamamlandığında hafızada tutulan en iyi yiyecek kaynağı algoritmanın keşfettiği çözümdür.

- Başlangıç Yiyecek Kaynaklarının Belirlenmesi: Algoritma ilk aşamada başlangıç

Girişler: MCN: Maksimum çevrim sayısı.
KS: Kolonideki toplam arı sayısı.
B: Araştırma uzayının boyutu.
$limit$: Görevli arının kaşif arıya dönüşebilmesi için aynı yiyecek kaynağı üzerinde yapacağı toplam araştırma sayısının limit değeri.
$amacFonk$: Yiyecek kaynaklarının değerlendirilmesi için gerekli amaç fonksiyonu.
Çıkış : $eniyiYK$: $amacFonk$ en iyi karşılayan yiyecek kaynağı.

```
tekrarSayısı=0
BaşlangıçDeğerleriAta()
YiyecekKaynaklarınıDeğerlendir()
while (tekrarSayısı < MCN) do
    GörevliArılarAşaması()
    GözetleyiciArılariçinOlasılıkHesapla()
    GözetleyiciArılarAşaması()
    EnİyiYiyecekKaynağınıHafızayaAl()
    KaşifArıAşaması()
    tekrarSayısı=tekrarSayısı+1
end while
return eniyiYK
```

Algoritma 2.1: ABC algoritmasının kaba kodu [77].

çözümlerini belirleyerek işe başlar. Algoritmada yiyecek kaynakları Denklem 2.1 ile çözüm uzayı üzerinde düzgün biçimde dağıtılır.

$$x_{ij} = x_j^{min} + rand(0,1) * (x_j^{max} - x_j^{min}) \tag{2.1}$$

Burada $i = 1, 2, ..., SN$ ve $j = 1, ..., D$ olmak üzere SN yiyecek kaynağı sayısı olup $KS/2$'ye eşittir. D ise optimize edilecek parametre sayısını ifade eder. x_j^{min}, x_j^{max}, j. parametrenin alabileceği alt ve üst sınırları ifade eder.

- Görevli Arıların Yiyecek Kaynaklarına Gönderilmesi: Her bir yiyecek kaynağı için bir görevli arı çalışmaktadır. Dolayısıyla görevli arı sayısı ile yiyecek kaynağı sayısı birbirine eşittir. Görevli arılar, ilgilendikleri yiyecek kaynaklarının komşu bölgesinde farklı yiyecek kaynaklarını değerlendirir. Daha iyi bir yer bulunması halinde yiyecek kaynağını günceller. Bu değişim işlemi Denklem 2.2 ile tanımlanır.

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \tag{2.2}$$

Denklem 2.2'de, $\vec{x}_i$ görevli arının mevcut yiyecek kaynağını, $\vec{v}_i$ aday yiyecek kaynağını ifade eder. Yeni çözüm üretimi için, başka bir yiyecek kaynağı (k) seçilerek her iki yiyecek kaynağındaki $[1, D]$ arası seçilen rastgele bir parametrenin (j) farkları rastgele ϕ_{ij} değeri ile ağırlıklandırılır ve (j) parametre değeri güncellenir. Burada parametre değerinin seçilen diğer yiyecek kaynağı ile farkının azalması durumunda değişim miktarı azalacak, daha dar bölgede ve daha hassas bir değer aranacaktır. Parametre değerinin alt ve üst sınırları aşması durumunda sınır değerlerine ötelenir. Temel ABC algoritmasında üretilen yiyecek kaynağının diğer parametre değerleri aynı tutulur. Elde edilen $\vec{v}_i$ yeni bir yiyecek kaynağını temsil eder, bunun kalitesi amaç fonksiyonu ile hesaplanarak, kalite değeri Denklem 2.3 ile bulunur. Eski yiyecek kaynağı ($\vec{x}_i$) ile yeni yiyecek kaynağının ($\vec{v}_i$) kalite değerleri karşılaştırılır. Eğer yeni yiyecek kaynağının kalite değeri daha iyi ise eski kaynak silinerek yeni yiyecek kaynağı hafızaya alınır. Deneme sayacı sıfırlanır. Aksi durumda görevli arı eski yiyecek kaynağına çalışmayı sürdürür. Yiyecek kaynağını geliştiremediği için görevli arı deneme sayacını bir artırır.

$$Kalite_i = \begin{cases} 1/(1+f_i) & , f_i \geq 0 \\ 1 + abs(f_i) & , f_i < 0 \end{cases} \tag{2.3}$$

- Gözcü Arıların Yiyecek Kaynağı Belirlemede Kullanacakları Olasılık Hesaplanması (Dans Benzetimi): Görevli arılar araştırmalarını tamamladıktan sonra kovana döner ve sahip oldukları nektarların kaynakları hakkında gözcü arılara bilgi verir. Gözcü arı dans alanındaki görevli arıları izleyerek yiyecek kaynaklarının kaliteleriyle orantılı bir ihtimalle bir yiyecek kaynağı bölgesini seçer. Burada her bir gözcü arı çoklu etkileşim sergilemekte ve yüksek olasılıkla daha iyi bir yiyecek kaynağı bölgesine gitmeye karar vermektedir. Temel ABC algoritmasında bu seçim işlemi rulet tekerleği yöntemi ile yapılır. Yiyecek kaynaklarının tekerlek üzerindeki sahip olduğu alanlar kalite değerleri ile orantılı biçimde dağıtılmıştır. Bu alan ya da seçilme olasılık değeri (p_i), Denklem 2.4 ile hesaplanır.

$$p_i = \frac{Kalite(\vec{x}_i)}{\sum_{j=1}^{SN}(Kalite(\vec{x}_j))} \tag{2.4}$$

Denklem 2.4'te, $Kalite(\vec{x}_i)$, i. kaynağın kalitesi, SN ise görevli arı sayısını ifade eder.

- Gözcü Arıların Yiyecek Kaynağı Bölgelerini Belirlemesi: Olasılık değerleri hesaplanmasının ardından her bir gözcü arı, sırasıyla her bir yiyecek kaynağı için [0,1] arasında rastgele bir değer üretir. Eğer p_i değeri bu değerden büyükse gözcü arı görevli arı gibi Denklem 2.2 ile yiyecek kaynağı çevresinde yeni bir kaynak araştırır. Yeni çözüm için kalite değeri hesaplanarak aynı görevli arıda olduğu gibi karşılaştırılır, karşılaştırma sonucunda ya yeni çözüm eskisinin yerine konulur, ya da eski çözümün deneme sayacı bir artırılır. Gözcü arılar, kalitesi daha yüksek yiyecek kaynaklarını daha yüksek olasılıkla tercih eder ve geliştirmeye çalışır. Ancak düşük kaliteli kaynakların da seçilme ihtimali vardır. Bu da popülasyona farklılık katar.

- Tükenen Kaynağın Terk Edilmesi ve Kaşif Arı Gönderilmesi: Görevli ve gözcü arılar çalıştıktan sonra çevrimin son aşamasında yiyecek kaynaklarının deneme sayaçları kontrol edilir. Deneme sayacı limit değerini aşmış bir yiyecek kaynağı bulunması durumunda ilgili yiyecek kaynağı hafızadan silinip, görevli arı yeni bir yiyecek kaynağı bulması için kaşif arıya dönüşür. Kaşif arı Denklem 2.1 ile yeni bir yiyecek kaynağı belirler ve kalitesini hesaplar. Temel ABC algoritmasında her çevrimde sadece bir kaşif arı çıkartılmasına izin verilmiştir.

- ABC Algoritmasının Kontrol Parametreleri: ABC algoritması az sayıda kontrol parametresi içeren oldukça basit bir meta-sezgisel algoritmadır. Sahip olduğu kontrol parametreleri MCN, SN ve $Limit$ dir. MCN algoritmanın kaç çevrim sürdürüleceğini belirler. SN kovandaki yiyecek kaynağı sayısıdır. MCN değeri ne kadar büyük seçilirse o kadar fazla öğrenme işlemi gerçekleşecektir. $Limit$, bir yiyecek kaynağının terk edilmesi için gerekli eşik sayısını ifade eder. $Limit$ değerinin $0.5xSNxD$ olması önerilmektedir [16, 80].

2.2. ABCMiner Algoritması

Bu bölümde kural tabanlı sınıflandırma modeli öğrenimi için ABC'ye dayalı geliştirilen ABCMiner algoritması açıklanacaktır.

ABCMiner, herhangi bir sınıflandırma probleminin çözümü için kullanılabilecek ihtiyaç duyulan kuralları sırasıyla keşfeden Yapay Arı Koloni algoritmasına dayalı yeni bir kural tabanlı sınıflandırma algoritmasıdır. ABCMiner algoritmasının sahip olduğu temel

özellikler aşağıda verilmiştir:

- Denetimli Öğrenme: ABCMiner, giriş öznitelikleri ve çıkış sınıfını içeren eğitim verilerini kullanıp denetimli makineli öğrenme gerçekleştirmektedir.

- Michigan Yaklaşımı: Popülasyondaki her çözüm sınıflandırma modelinin bir parçası olan tek kuralı tanımlar. ABC, her çalıştırıldığında çözümün sadece bir parçasını öğrenir.

- Sürekli Sayı ile Kodlama: Algoritma kuraldaki her bir şart için özniteliğin türüne bakmadan $[0, 1]$ arası değer araştırır. Halbuki kategorik öznitelikler için ikili temsil daha uygun iken yine bu şekilde sürekli araştırma yapılmasının sebebi ABC algoritmasının sürekli sayılar üzerinde araştırma yapabilmesidir. Kategorik öznitelikler için $[0, eşikDeğeri]$ arasında çıkartılan bir şart dönüşüm işlemine tabi tutulur ve gerçek değeri elde edilir. Sayısal öznitelikler için ise $[0, eşikDeğeri]$ aralığındaki normalleştirilmiş değer ise gerçek değer aralığı kullanılarak asıl değerine dönüştürülür. Değişken uzunlukta kuralların araştırılabilmesi ve gereksiz özniteliklerin kuraldan çıkartılabilmesini sağlamak için $[0, 1]$ arası bir ***eşikDeğeri*** tanımlanmıştır ve çalışma esnasında ***eşikDeğeri***'nin üstüne çıkan parametrelerin temsil ettiği öznitelikler kuraldan çıkarılmıştır.

- İteratif Kural Keşfetme: ABC çözüm uzayındaki küresel en iyi çözümü araştıran bir optimasyon algoritması olduğundan dolayı Michigan yaklaşımı ile kodlanmış popülasyon bireylerini geliştirerek, her çalıştırıldığında eğitim örneklerini en yüksek doğrulukla sınıflandıran tek kural öğrenmektedir. Bu sebeple kural kümesindeki her bir kural için, ABC algoritması tekrarlı biçimde çalıştırılır. Her çalıştırma sonucunda bir kural elde edilir. Bu kuralla doğru biçimde sınıflandırılmış eğitim örnekleri çıkartılır. Kalan örnekler ile kural bulma işlemi tekrarlanır. Kalan eğitim örneklerinin sayısı sonraki bölümde açıklanacak olan orana indirgenince yeni kural keşfi döngüsü durdurulur.

- Kural Basitleştirme İşlemi: ABC algoritması kural öğrendikten sonra kural üzerinde basitleştirme işlemi gerçekleştirilir. Bir döngü ile her bir koşul sırasıyla çıkartılıp kural kalitesinin artış gösterip göstermediğine bakılır. Kural kalitesi arttıysa o koşula

kuralda yer verilmez. Bütün koşullar bu şekilde değerlendirilerek hem daha basit hem de doğruluğu daha yüksek kural elde edilir.

- Son Basitleştirme İşlemi: ABCMiner, kuralların keşfedilmesi işlemini tamamladıktan sonra, son basitleştirme işlemi gerçekleştirir. Bu aşamada kurallar kendi aralarında değerlendirilerek aynı çözüm bölgesini kapsayan ya da temel sınıf ile aynı sınıfı içeren gereksiz kurallar çıkartılır. Son basitleştirme işlemi ile birlikte daha basit bir sınıflandırma modeli elde edilmektedir.

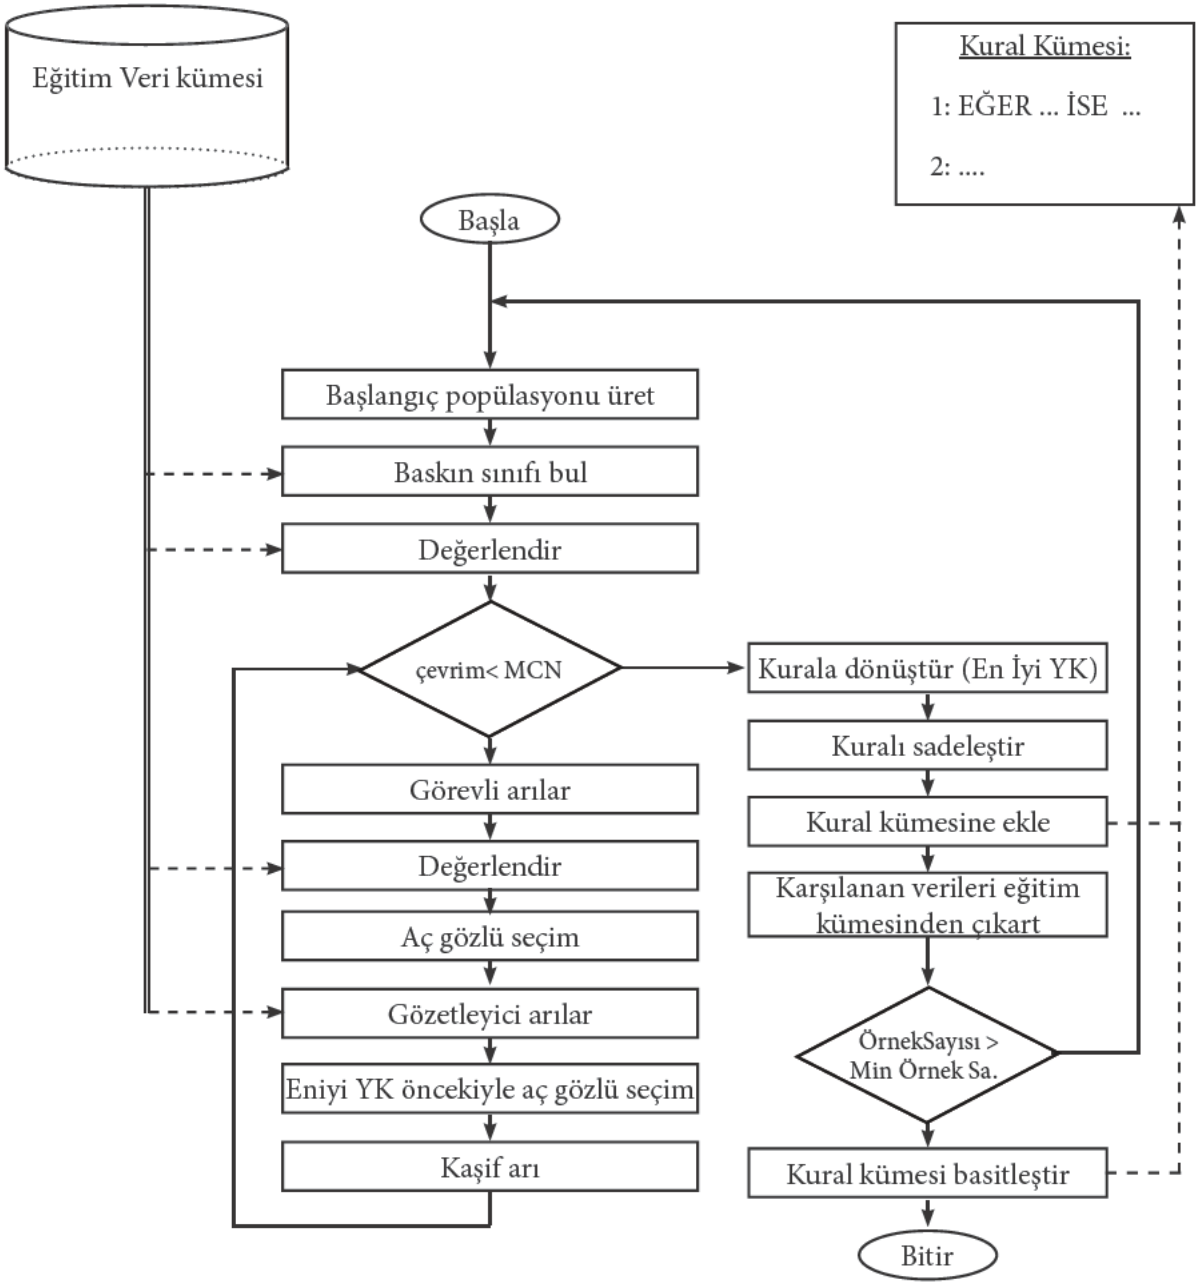
ABCMiner algoritmasının kaba kodu Algoritma 2.2'de ve akış diyagramı Şekil 2.1'de verilmiştir. Algoritmanın girişi eğitim örnekleri, çıkışı ise kural kümesidir. Araştırmaya başlamadan önce eğitim veri kümesindeki örnekler $[0, eşikDeğeri]$ arasında normalleştirilir (4. Adım). Sonra eğitim kümesini belirli seviyeye azaltıncaya kadar tekrarlanan ana kural öğrenme döngüsü çalıştırılır (7.-36. Adımlar). Bu döngü içinde kurallar sırası ile keşfedilmektedir. Bir kuralın öğrenilmesi için ilk önce o kuralın vereceği sınıf kararı belirlenir (8. Adım). Daha sonra yiyecek kaynaklarının başlangıç değerleri atanıp (9. Adım) doğruluk değerleri ölçülerek (10. Adım) ABC algoritmasının adımları başlatılır. En yüksek doğruluk kalitesine sahip yiyecek kaynağı en iyi çözüm olarak hafızaya alınır (11. Adım). Bundan sonra maximum tekrar sayısı (MCN) kadar tekrarlanan ve çözümleri araştırma stratejisi doğrultusunda geliştiren ABC algoritması ana döngüsü (14.-31. Adım) gerçekleşmektedir. Bunun için önce görevli arılar (15. Adım) daha sonra komşuluk araştırması yapan gözetleyici arılar (19. Adım) yiyecek kaynaklarına gönderilir.

Görevli arılar aşamasında bulunan yiyecek kaynaklarının kaliteleri (16. Adım) değerlendirildikten sonra eski ile yeni yiyecek kaynakları arasında aç gözlü seçim işlemi gerçekleştirilir (17. Adım). İlgili çevrimde elde edilen en kaliteli yiyecek kaynağı hafızada tutulur (20. Adım). Çevrimin son aşamasında, görevli ve gözetleyici arıların çözüm geliştirememe sayaçları kontrol edilerek *limit* değerini aşan varsa kaşif arıya dönüştürülür (22.-25. Adımlar). En iyi yiyecek kaynağı güncellenerek hafızada tutulur (26.-29. Adımlar). ABC döngüsü tamamlanınca tutulan en iyi yiyecek kaynağı sınıflandırma kuralına dönüştürülür (32.Adım) ve basitleştirilme işlemine tabi tutulur (33. Adım). Elde edilen basit kural kural kümesine (*kuralSeti*) eklenir (34. Adım) ve doğru

Girişler: *eğitimÖrnekleri* : Eğitim için kullanılacak nitelik-sınıf örnekleri.
MCN: Toplam iterasyon sayısı.
KS : Kolonideki toplam arı sayısı.
limit: Görevli arının kaşif arıya dönüşebilmesi için aynı yiyecek kaynağı üzerinde yapacağı toplam araştırma sayısının limit değeri.
durdurmaYüzdesi: Algoritmanın durdurulabilmesi için yeterli sınıflandırılmamış eğitim örneklerinin yüzdesi.
eşikDeğeri: Niteliğin kuralda yer almaması için gerekli alt sınır değeri.
Çıkış : *kuralSeti*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan anlamlı ve ilginç kurallar kümesi.
Data: *SN*: Algoritmadaki yiyecek kaynağı sayısı.
NS: Araştırılan problemdeki nitelik sayısı.
B: Araştırma uzayının boyutu.
as[B], *us[B]*: her bir nitelik için alt ve üst sınır değerleri.
normEğitim: [0, *eşikDeğeri*] arasında normalleştirilmiş eğitim örnekleri.
toplamÖrnekSayısı: Eğitim örneklerinin sayısı.
maxSınıf: En fazla eğitim örneğine sahip sınıf.
minÖrnekSayısı: Yeni kural döngüsünü durdurmak için gerekli min örnek sayısı.
YK, *görevliArılar*: [*SN* x *B*] boyutunda çözüm matrisleri.
normFit, *normFitE*: Yiyecek kaynaklarının eğitim kümesi için sınıflandırma performansları.
temelSınıf: Hiç bir kural karşılanmadığında atanacak sınıf değeri.

```
1: SN= KS / 2
2: B= 2 * NS
3: kuralSeti= []
4: normEğitim= Normalleştir(eğitimÖrnekleri,0,eşikDeğeri)
5: toplamÖrnekSayısı= ÖrnekSayısı(eğitimÖrnekleri)
6: minÖrnekSayısı= toplamÖrnekSayısı * durdurmaYüzdesi / 100
7: while (SınıfSayısı(normEğitim) > 1 AND
   ÖrnekSayısı(normEğitim) > minÖrnekSayısı) do
8:     maxSınıf= BaskınSınıfıBul(normEğitim)
9:     YK= BaşlangıçDeğerleriAta(nitelikler, SN, B)
10:    normFit= Değerlendir(YK)
11:    EnİyiYK= EnİyiYKBul(YK, normFit)
12:    EnIyiFit= Değerlendir(EnIyiYK)
13:    çevrim= 0
14:    while (çevrim < MCN) do
15:        görevliArılar= GörevliArılarAdımı(YK)
16:        normFitE= Değerlendir(görevliArılar)
17:        YK= AçGözlüSeçim(YK, görevliArılar, normFit, normFitE)
18:        normFit= Değerlendir(YK)
19:        YK= GözetleyiciArılarAdımı(YK)
20:        AdayYK= EnIyiYKBul(YK, normFit)
21:        AdayFit = Değerlendir (AdayYK)
22:        kaşifİndisi= KaşifArıyaDönüşenVarMı(YK, limit)
23:        if (kaşifİndisi > 0) then
24:            YK[kaşifİndisi,B]= YeniYiyecekKaynağıBelirle()
25:        end if
26:        if ((AdayFit > EnİyiFit) then
27:            EnIyiYK= AdayYK
28:            EnİyiFit= AdayFit
29:        end if
30:        çevrim= çevrim + 1
31:    end while
32:    kural= KuralaDönüştür(EnİyiYK, maxSınıf, nitelikler, as, us)
33:    kural= KuralBasitleştir(kural)
34:    kuralSeti= YeniKuralEkle(kuralSeti, kural)
35:    normEğitim= SınıflandırılanÖrnekleriÇıkart(normEğitim, kural)
36: end while
37: temelSınıf= BaskınSınıfıBul(normEğitim)
38: kuralSeti= TemelSınıfEkle(kuralSeti, temelSınıf)
39: kuralSeti= KuralKümesiniBasitleştir(kuralSeti)
return kuralSeti
```

Algoritma 2.2: ABCMiner algoritması kaba kodu.



Şekil 2.1. ABCMiner algoritması öğrenme süreci akış diyagramı.

biçimde sınıflandırılmış örnekler eğitim kümesinden çıkartılır (35. Adım). Kuralların keşfedilmesi tamamlandıktan sonra kalan örnekler arasındaki baskın sınıf temel sınıf biçiminde kural kümesine eklenir (37. ve 38. Adım). Algoritma en son adımda kural kümesi üzerinde basitleştirilme işlemi gerçekleştirir (39. Adım). Böylece ABCMiner, eğitim örneklerini en doğru biçimde sınıflandıran bir sınıflandırma modeli (*kuralSeti*) ortaya koyar. Burada kısaca açıklanan adımlar hakkında detaylı bilgi ilerleyen kısımda verilecektir.

2.2.1. ABCMiner Algoritmasında Kural Temsili

ABCMiner algoritmasında araştırılan her bir kural, *"EĞER koşul$_1$ VE koşul$_2$ ... VE koşul$_k$ İSE SINIF$_x$"* biçiminde ön şart ve sınıf kararı olmak üzere iki kısımdan oluşmaktadır. Denklem 2.5'te ABCMiner algoritmasının yiyecek kaynağının araştırdığı çözüm verilmiştir. Her bir koşul Denklem 2.6'da belirtildiği gibi öznitelik türüne göre farklı değerler alır. Karar sınıfı bütün çözümler için aynı olduğundan dolayı yiyecek kaynağında kuralın sınıf kısmı belirtilmemiş sadece şart kısmı belirtilmiştir. Kuralın karar sınıfı (8. adım) belirlendikten sonra çözümlere $[0, 1]$ aralığında rastgele değerler atanır (9. Adım).

$$YiyecekKaynağı_i = \quad [koşul_{i,1}, \quad \ldots \quad , koşul_{i,m}] \tag{2.5}$$

$$koşul_{i,l} = \{SembolikKoşul, SayısalKoşul\} \tag{2.6}$$

Kural koşulu, özniteliğin türüne göre bir yada iki sayı değeri ile temsil edilir. ABCMiner'de, sayısal öznitelikler iki sayı değeri içeren $SayısalKoşul$ ile (Denklem 2.7), ayrık ve ikili biçimdeki kategorik öznitelikler ise tek sayı değeri içeren $SembolikKoşul$ ile (Denklem 2.8) araştırılır. Bir koşulun ilk değeri $eşikDeğer$'den büyük bir değere sahip olması halinde o koşul kuralda yok sayılır.

$$SayısalKoşul_{i,j} = \quad [merkez_{i,j}, yarıçap_{i,j}] \tag{2.7}$$

$$SembolikKoşul_{i,k} = \quad [değer_{i,k}] \tag{2.8}$$

Denklem 2.7'de verilen koşuldaki iki sayıdan birincisi geçerli değer aralığının merkezini, ikincisi ise bu merkez etrafında ne kadar bir yarıçapta bölgenin kapsandığını belirtir. [0,1] aralığında değer alan bu parametreler özniteliğin gerçek değer aralığı yardımıyla kural içindeki şarta dönüştürülerek kullanılır. Tanımlanan şart ile bir örneğin karşılanması için örneğin ilgili öznitelik değeri Denklem 2.9'da verilen aralık içinde yer almalıdır.

Denklemdeki Min_j ve Max_j değerleri özniteliğin alabileceği maksimum ve minimum sayı değerleridir.

$$\begin{gathered}\frac{(merkez_{i,j}-yarıÇap_{i,j})*(Max_j-Min_j)}{Eşik} \\ \leq ÖznitelikDeğer_j \leq \\ \frac{(merkez_{i,j}+yarıÇap_{i,j})*(Max_j-Min_j)}{Eşik}\end{gathered} \tag{2.9}$$

Denklem 2.8'de verilen $SembolikKoşul$, ikili ve ayrık tipteki kategorik özniteliklerin temsili için kullanılır. $[0, eşik]$ aralığı $k.$ öznitelik için ayrık durum sayısı ($DurumSayısı$) kadar eşit aralıklara bölünmüştür. Tanımlanan $SembolikKoşul$ ile bir örneğin karşılanması için, örneğin ilgili öznitelik değeri ($ÖznitelikDurum_k$), Denklem 2.10'da verildiği gibi karşılaştırılır.

Şekil 2.2'de örnek bir veri kümesi (lenf grafisi) için yapılan araştırmada çözümleri temsil eden 8 yiyecek kaynağı gösterilmiştir. Şekilde öznitelik adları üstte ve yiyecek kaynakları (YK_i) adları solda verilmektedir. Yiyecek kaynaklarının belirlediği ön şart ve sınıf değeri birlikte bir kural tanımlamaktadır. Yiyecek kaynaklarının başlangıç değerinin belirlenmesinin anlatılacağı sonraki bölümde yiyecek kaynaklarından elde edilen kural verilecektir.

$$\frac{Eşik * ÖznitelikDurum_k}{DurumSayısı} \leq değer_{i,k} < \frac{Eşik * (1 + ÖznitelikDurum_k)}{DurumSayısı} \tag{2.10}$$

2.2.2. Kural Kümesi ve Sınıflandırma için Kullanımı

Sınıflandırma modeli (Denklem 2.11), ABCMiner algoritmasının öğrendiği kuralların ve temel sınıfın bir araya getirilmesi ile elde edilir. Bu model, sınıfı bilinmeyen yeni örneklerin sınıflandırılması işleminde kullanılabilir. Problem uzayındaki sınıfı bilinmeyen yeni bir örnek ile karşılaşıldığında, sınıflandırma modelindeki kurallar ile ilk kuraldan başlanarak sırasıyla karşılaştırılır. Bir kuralın koşul ifadeleri örneğin öznitelik değerleri ile birebir örtüşürse, ilgili kuralın karar sınıfı sistemin sınıf tahmini olarak verilir. Hiç bir kuralın örneği karşılamaması durumundaysa verilecek sınıf kararı temel sınıfdır.

	lymphatics	block of affere	bl. of lymph c	bl. of lymp_s	by_pass	extravasates	regeneration_of	early uptake in	*lymph node dim.	*lymph node enl.	changes in l.	defect in node	changes in node	change in stru	special forms	dislocation of	exclusion of no	*no of nodes in int
YK_1:	0.5	0.7	0	0.3	0.1	1	0.22	0.4	[0.8;0.1]	[.9;0.2]	0.63	0.04	0.8	0.1	0.9	1	0.1	[.2;0.4]
YK_2:	0.9	0.17	0.1	0.8	0.2	0.9	0.16	0.21	[.9;.05]	[.1;0.3]	0.2	0.36	0.5	1	0.88	1	0	[.1;0.9]
YK_3:	0.1	0.22	0.78	0.4	0.77	0.1	0.66	0.27	[.4;.7]	[.88;.02]	0.66	0.39	1	0.44	0.97	0.51	0.3	[0;0.3]
YK_4:	0.5	0.97	0.45	0.41	0.3	0.11	0.23	0.16	[.3;0.1]	[.2;.3]	0.93	0.48	0.3	0.21	0.2	0.06	0.85	[.8;0.1]
YK_5:	0	0.99	0.6	0.10	0.85	0.19	0.1	0.65	[1;0.5]	[0.6;0.1]	1	0.81	1	0.1	0.22	0.77	.99	[1;0.9]
YK_6:	0.05	0.82	0.88	0.85	0.89	0.91	0.9	0.84	[.85;.12]	[0.8;0.1]	0	0.9	0.93	1	1	0.81	.97	[.81;0.1]
YK_7:	0.89	1	0.3	0.3	1	0.79	1	0.92	[.9;0.1]	[.9;0.2]	0.4	0.2	0.1	0.9	0.39	1	0	[0;0.3]
YK_8:	1	1	0.1	0.3	0.2	0.33	0.5	0.86	[0;0.1]	[.77;.12]	0.11	0	0.3	1	0.9	1	1	[0;0.2]

Şekil 2.2. Lenf grafisi için ABCMiner'a ait örnek bir başlangıç çözüm popülasyonu.

$$\begin{aligned} Kural_1 = \quad & Koşul_{1,1} \quad ... \quad Sınıf_1 \\ ... \quad & ... \quad ... \\ Kural_n = \quad & Koşul_{n,1} \quad ... \quad Sınıf_n \\ TemelSınıf = \quad & \quad\quad\quad\quad Sınıf_x \end{aligned} \tag{2.11}$$

2.2.3. ABCMiner Algoritmasının Kontrol Parametreleri

ABCMiner algoritması; MCN, SN, $Limit$, $durdurmaYüzdesi$ ve $eşikDeğeri$ olmak üzere beş kontrol parametresine sahiptir. ABC algoritmasında yeralan temel üç kontrol parametresi ABCMiner algoritması için de geçerlidir: MCN algoritmanın çalışacağı toplam çevrim sayısı, SN kovandaki görevli arı sayısı; yeni tanımlı yiyecek kaynağı sayısı, $Limit$ ise bir görevli arının yiyecek kaynağını terk ederek kaşif arıya dönüşmesi için sağlanması gereken deneme sayısıdır. $durdurmaYüzdesi$, algoritmanın durdurulması için eğitim örneklerinin sınıflandırılamadan kalan sınır oranını belirtir. $eşikDeğeri$, yiyecek kaynağındaki bir koşulun, kural içinde yer alıp almaması için belirlenen $[0, 1]$ arası eşik değeridir.

2.2.4. Başlangıç Yiyecek Kaynaklarının Belirlenmesi

ABCMiner algoritmasında her kural keşfi işleminde ilk önce, yiyecek kaynaklarına rastgele parametre değeri ataması gerçekleştirilir. 8. adımda mevcut eğitim örnekleri içinde baskın olan sınıf belirlendikten sonra arılar tarafından yiyecek kaynaklarında araştırılacak ön şart kısmı 9. adımda [0,1] arası rastgele değer atanarak belirlenir. Belirlenen rastgele değer $eşikDeğeri$'den küçük olması o özniteliğin şart içinde yer almasını sağlamaktadır.

Şekil 2.2'de verilen Lenf grafisi sınıflandırma problemi için kolonideki arıların sahip olduğu yiyecek kaynaklarının örnek bir başlangıç durumu verilmiştir. Bu problemde 4 sınıf değeri ve 18 öznitelik (9 ikili, 6 sembolik, 3 tamsayı) vardır. $eşikDeğeri$ 0,8 olmak üzere şekilde gösterilen 8 yiyecek kaynağından 6. yiyecek kaynağı (FS_6), sadece iki öznitelik değeri $eşikDeğeri$'nden küçük olduğu için, "*EĞER* ***lymphatics*** *öznitelik değeri 'normal' ve* ***changes in lym*** *değeri 'bean' İSE* " biçiminde bir kural ön şartı verecektir.

2.2.5. Yiyecek Kaynaklarının Kalitesinin Hesaplanması

Algoritma 2.2'nin, 10., 16., 18. ve 21. adımlarında yiyecek kaynaklarının kaliteleri hesaplanmaktadır. Her bir yiyecek kaynağı için eğitim örnekleri kullanılarak elde edilen doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP), yanlış negatif (FN) oranları, Denklem 2.12 yardımıyla yiyecek kaynağının probleme olan kalitesini belirler.

$$Kalite(kural_i) = Duyarlılık_i * Belirlilik_i = \frac{TP_i}{(TP_i + FN_i)} * \frac{TN_i}{(TN_i + FP_i)} \quad (2.12)$$

2.2.6. Görevli ve Gözetleyici Arıların Yiyecek Kaynaklarına Gönderilmesi

ABCMiner, yeni bir kural öğrenimi için ABC algoritmasını başlattıktan sonra görevli, gözetleyici ve kaşif arı aşamalarını sırasıyla çalıştırır. Algoritma 2.2'de 15. adımda görevli arılar, 19. adımda ise gözetleyici arılar yiyecek kaynaklarına gönderilir. Görevli arılar geri döndükten sonra yeni yiyecek kaynaklarının kaliteleri 16. adımda değerlendirilir. 17. adımda yeni yiyecek kaynakları ile öncekiler karşılaştırılır ve aç gözlü seçim işlemi çalıştırılır ve kalitesi yüksek olanlar bir sonraki adıma aktarılır. Görevli ve

gözetleyici arılar adımında her bir yiyecek kaynağının rastgele seçilen bir parametresi başka bir arının yiyecek kaynağının parametresi yardımıyla Denklem 2.2'deki gibi güncellenir. Böylece yiyecek kaynağının komşuluk araştırması gerçekleştirilir [81]. Komşuluk araştırması sırasında belirlenen yeni değer, [0,1] arası minimum veya maksimum sınır değerini aştığında üst değere eşitlenir.

2.2.7. Tükenen Kaynağın Terk Edilmesi ve Kaşif Arı Gönderilmesi

22. ve 25. adımlar arasında kaşif arı işlemi gerçekleştirilir. $Limit$ parametresi görevli bir arının çözüm olarak belirlediği yiyecek kaynağını daha iyi bir noktaya geliştiremediği maksimum takılma adım sayısını ifade eder. Bu değere ulaşan bir görevli arı daha iyi bir komşu yiyecek kaynağı bulamayacağına ve yiyecek kaynağının tükendiğine karar vererek, kaşif arıya dönüşür. Böylece rastgele çözüm uzayı içinde başka bir yiyecek kaynağı araştırmasına çıkar. Kaşif arı işlemi, algoritmanın bölgesel çözümlere takılmadan küresel çözümü elde edebilmek için yeni ve farklı çözümler araştırabilmesi imkanı vermektedir. Kaşif arı işleminde rastgele parametre değerleri ile yeni bir yiyecek kaynağı oluşturulur.

2.2.8. En İyi Yiyecek Kaynağının Hafızaya Alınması

26. ve 29. adımlar arasında en iyi yiyecek kaynağının hafızaya alınması gerçekleştirilir. Her çevrim sonunda elde edilen en yüksek kaliteye sahip yiyecek kaynağı en iyi yiyecek kaynağı ile karşılaştırılır. Yeni yiyecek kaynağının kalitesi daha yüksek ise en iyi yiyecek kaynağı olarak saklanır.

2.2.9. Keşfedilen Yiyecek Kaynağının Kurala Dönüştürülmesi

ABC algoritmasının temel adımlarının MCN kez tekrarı ile $EnIyiYK$ eğitim örneklerini en yüksek doğruluk ile karşılayan kuralın ön şart kısmını verir. Bu yiyecek kaynağı Algoritma 2.2'deki 32. adımda daha önce belirlenen karar sınıfı ile birlikte kurala dönüştürülür. Sınıflandırma kuralı $eşikDeğeri$ parametresinden küçük sayısal değerlere sahip olan parametreleri öznitelik koşuluna dönüştürerek *"EĞER koşul*$_1$ *VE koşul*$_2$ *... VE koşul*$_k$ *İSE SINIF*$_x$*"* biçiminde kural elde edilir. Yiyecek kaynağında [0,$eşikDeğeri$]

arasında yer alan koşul değerleri ilgili özniteliğin sınır değerleri kullanılarak Denklem 2.9 ve 2.10 ile gerçek değere dönüştürmektedir.

2.2.10. Kuralın Basitleştirilmesi

Algoritmanın 33. adımında elde edilen kural daha kaliteli ve basit biçime dönüştürülmeye çalışılır. Bunun için sırasıyla koşullar kontrol edilir ve kaliteyi düşüren bir etkiye sahip olup olmadığı değerlendirilir. Koşul çıkarıldıktan sonra elde edilen kuralın kalitesi eşit ya da daha yüksek oluyorsa o koşul kuraldan çıkartılır. Kural basitleştirme işleminin ayrıntıları Algoritma 2.3'te verilmiştir.

2.2.11. Yeni Kuralın Kural Kümesine Eklenmesi ve Eğitim Kümesinin Küçültülmesi

Öğrenilen yeni kural 34. adımda sınıflandırma modelini oluşturan kural kümesi içine eklenir. 35. adımda yeni kuralın karşılayarak doğru biçimde sınıflandırdığı eğitim örnekleri silinir. Eğitim örnekleri $durdurmaYüzdesi$ ile verilen orana kadar azaltılıncaya kadar kural öğrenim aşamaları tekrarlanır.

2.2.12. Temel Sınıfın Eklenmesi ve Kural Kümesinin Basitleştirilmesi

Kural öğrenme döngüsü bittikten sonra 37. adımda elde kalan eğitim örnekleri içinde en fazla örneğe sahip olan baskın sınıf belirlenir. 38. adımda varsayılan temel sınıf olarak kural kümesine eklenir. Sınıflandırma işlemi yapılırken kuralların hiçbirinin örneği tam karşılamadığı durumlarda sistemin vereceği sınıf kararı temel sınıf olacaktır. 39.

Girişler: *NS* : Problemdeki öznitelik sayısı.
Kural: Keşfedilen sınıflandırma kuralı.
Kalite: Keşfedilen kuralın eğitim örnekleri karşısındaki doğruluk değeri.
Çıkış : *BasitleştirilmişKural*: Algoritmanın keşfettiği, aynı zamanda basit ve eğitim örneklerini en doğru sınıflandırılan kural.

```
for i ← 1 to NS do
    adayKural = KoşulÇıkart(Kural,i)
    adayKalite = KuralDeğerlendir(adayKural)
    if (adayKalite ≥ Kalite) then
        i = 0
        Kural = adayKural
        Kalite = adayKalite
    end if
end for
return Kural
```

Algoritma 2.3: Kural basitleştirme işleminin kaba kodu.

adımda, daha basit bir model araştırmak için kural kümesindeki kurallar kendi aralarında karşılaştırılır ve genel doğruluğu düşüren ya da gereksiz olduğu belirlenen kurallar varsa çıkartılır. Algoritma 2.4'te kural kümesi basitleştirme adımları verilmiştir. Hiç bir kuralın karşılamadığı örneğe temel sınıf kararı verileceği için basitleştirme işleminin ilk aşamasında temel sınıf ile aynı sınıfa karar veren ve sonrasında farklı bir sınıfa ait kural bulunmayan en alttaki kurallar varsa kural kümesinden çıkartılır. İkinci aşamada, kural kümesindeki altta yer alan kurallar daha üstteki kuralların herhangi birinin daha özelleşmiş bir biçimi (alt kümesi) olup olmadığı araştırılır. Böyle bir durumda üstteki kural tarafından karşılanan örnekler daha aşağılarda yer alan bu özelleşmiş kural ile hiç bir zaman test edilemeyecektir. Bundan dolayı gereksiz olan bu tür özelleşmiş kurallar silinir. Son olarak hiç koşul içermeyen kurallar varsa onlar da silinir. Böylece gereksiz kurallardan temizlenen $kuralSeti$ ABCMiner algoritmasının öğrendiği sınıflandırma modeli olarak ortaya konulur.

Girişler: *kuralSeti* : Keşfedilen sınıflandırma kümesi.
Çıkış : *BasitleştirilmişKuralSeti*: Algoritmanın keşfettiği kural kümesindeki, gereksiz kurallar çıkarılarak elde edilen sınıflandırma modeli.
Data: *KS*: Kural kümesindeki kural sayısı.
temelSınıf: Temel sınıf.

$i = KS$
$devamet = true$
while $(devamet == true)$ **do**
  if $(Sınıf(kuralSeti[i]) == temelSınıf)$ **then**
    $kuralSeti$ = kuralÇıkart($kuralSeti$,i);
    $KS = KS - 1$
    $i = i - 1$
  else
    $devamet = false$
  end if
end while
for $i \leftarrow KS - 1$ to 1 **do**
  $j = i - 1$
  $devamet = true$
  while ($j \geq 1$ and $devamet == true$) **do**
    if $(kuralSeti[i] \subseteq kuralSeti[j])$ **then**
      $kuralSeti$ = kuralÇıkart($kuralSeti$,i);
      $devamet = false$
    end if
    $j = j - 1$
  end while
end for
for $i \leftarrow 1$ to $KS - 1$ **do**
  if $(KoşulSayısı(kuralSeti[i]) == 0)$ **then**
    $kuralSeti$ = kuralÇıkart($kuralSeti$,i);
  end if
end for
$BasitleştirilmişKuralSeti = kuralSeti$
return $BasitleştirilmişKuralSeti$

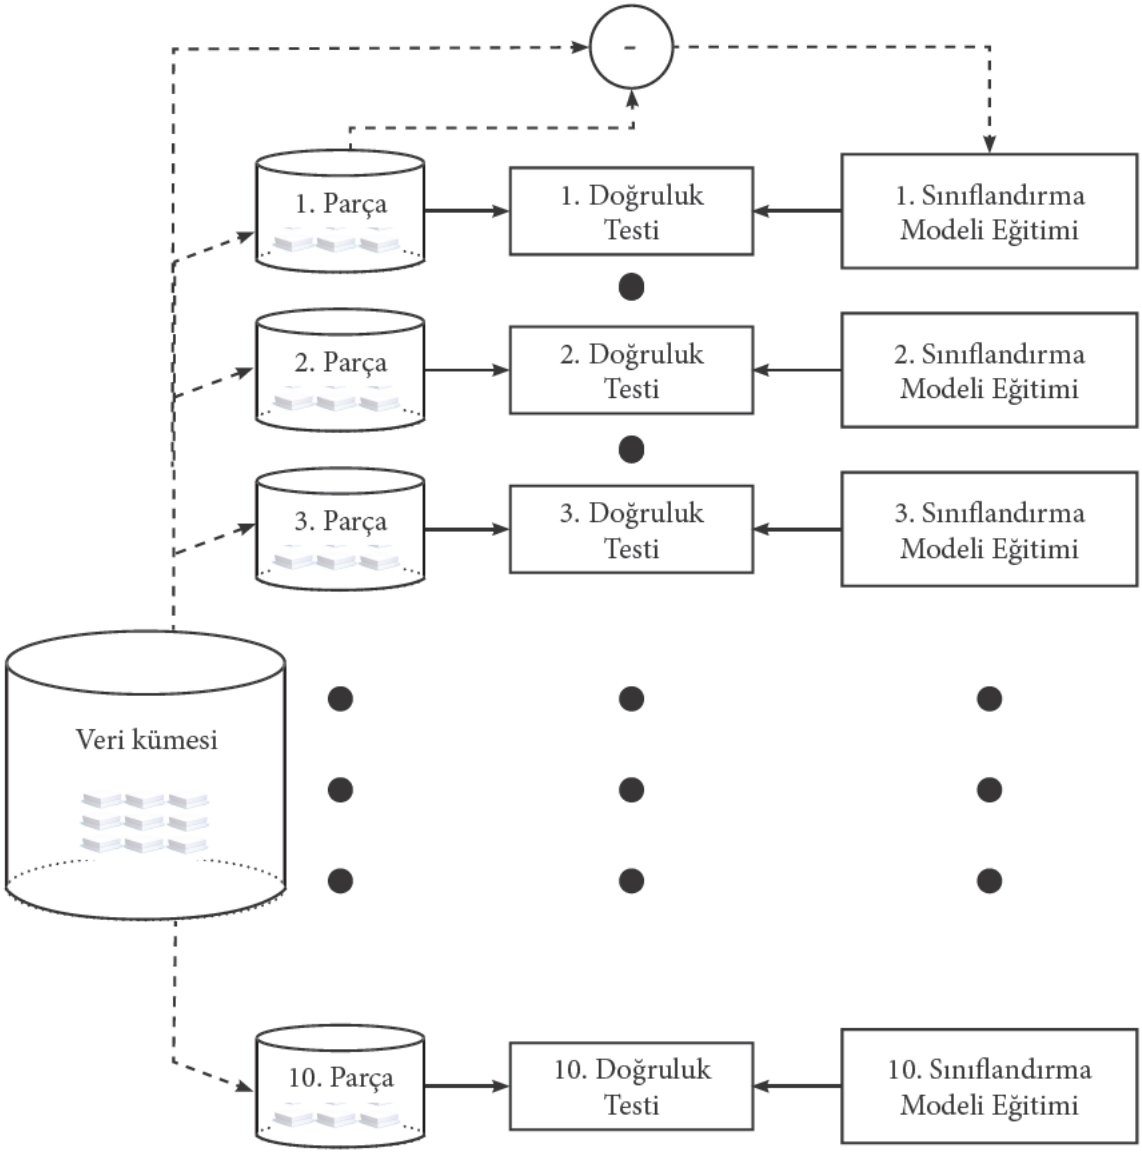
Algoritma 2.4: Kural kümesi basitleştirme işleminin kaba kodu.

2.3. Deneyler

Bu bölümde ABCMiner algoritmasının performansını değerlendirmek üzere iki farklı deney düzeneği hazırlanmış ve yapılan deneyler sonucu elde edilen doğruluk sonuçları farklı algoritmalar ile elde edilen sonuçlar ile karşılaştırılmıştır.

2.3.1. ABCMiner Algoritmasının Sınıflandırma Test Problemleri Üzerindeki Doğruluk Analizi

Literatürde sıklıkla kullanılan ve ayrıntıları EK-1'de verilen 13 farklı sınıflandırma problemi üzerinde ABCMiner algoritması denenmiş ve algoritmanın elde ettiği sonuçlar 6 farklı sınıflandırma algoritması ile karşılaştırılmıştır. Rakip algoritmaların literatürdeki yayınlarda verilen ve bu çalışmada da kullanılan kontrol parametre değerleri Tablo 2.1'de sunulmuştur. Daha doğru değerlendirme yapabilmek için problemler 10 kat çapraz doğrulama (10 fold cross validation) yöntemi ile sınanmıştır. 10 kat çapraz doğrulama yönteminde veri kümesi Şekil 2.3'te gösterildiği gibi 10 eşit parçaya rastgele ayrılıp 10 ayrı eğitim gerçekleştirilir. Her eğitimde farklı bir parça test işlemi için ayrılır ve geri kalan 9 kısım ile model eğitilir. Çapraz doğrulama yöntemi sonrası ortaya çıkan sonuçların ortalaması alınarak daha doğru bir değerlendirme yapılır. Meta-sezgisel algoritmalar için rastgele başlangıç durumunun ortaya çıkaracağı hata oranını gidermek ve daha nesnel sonuçlar elde etmek için deneyler 5 farklı başlangıç çözümü popülasyonu kullanılarak tekrarlanmıştır. Böylece ABCMiner ve meta-sezgisel gruba giren diğer beş algoritma her bir problem için 5 farklı başlangıç değeri kullanılarak 10 kat çapraz doğrulama yöntemi ile ellişer kez çalıştırılmış ve ortalama performansları karşılaştırılmıştır. Meta-sezgisel gruba girmeyen C4.5 algoritması sadece 10 kat çapraz doğrulama işlemine tabi tutulmuştur. Test problemleri üzerinde doğruluk analizi için (6 meta-sezgisel algoritma) x (13 problem) x (5 farklı rastgele başlangıç) x (10 kat çapraz doğrulama) ve C4.5 algoritması için (1 algoritma) x (13 problem) x (10 kat çapraz doğrulama) olmak üzere toplam 4030 deney gerçekleştirilmiştir. Her deney sonunda eğitim doğruluğu, test doğruluğu, çalışma süreleriyle modelin kural ve koşul sayıları her bir algoritma-problem çifti için ayrı ayrı not edilmiştir. ABCMiner Java



Şekil 2.3. 10 kat çapraz doğrulama yöntemi.

programlama dili kullanılarak diğer algoritmaları da barındıran KEEL [132] aracı üzerinde kodlanmıştır. Deneyler Intel(R) Core(TM) i7 3.5 Ghz işlemci ve 16 Gb belleğe sahip kişisel bilgisayarda gerçekleştirilmiştir.

Şekil 2.4, 2.5, 2.6, 2.7, 2.8, 2.9 ve 2.10'da 13 farklı problem için algoritmaların elde ettiği eğitim ve test sonuçları ile sonuçların özetini gösteren kutu grafikleri verilmiştir. Tablo 2.2, Tablo 2.3, Tablo 2.4 ve Tablo 2.5, 13 farklı problem üzerinde 7 farklı algoritma ile elde edilen sırasıyla eğitim ortalamaları, eğitim standart sapmaları, test ortalamaları ve test standart sapmaları sonuçlarını göstermektedir. Tablolarda parantez içinde verilen rakamlar elde edilen sonuçlar doğrultusunda her bir algoritmanın algoritmalar içindeki

Tablo 2.1. Algoritmaların kontrol parametrelerin deneylerde kullanılan değerleri [51, 60, 132].

	Algoritma	Parametre Değerleri
1	ABCMiner	Toplam Arı Sayısı (KS): 20, Limit: 100, Toplam Çevrim Sayısı (MCN): 1000, Sınıflandırılmamış Max Örnek Oranı: 0,1, Eşik Değeri: 0,1
2	LDWPSO	Parçacık Sayısı: 20, Maksimum İterasyon: 1000, Sınıflandırılmamış Max Örnek Oranı: 0,1, Eşik Değeri:0,1, Sınır. Katsayısı: 0,73, W_{max}: 0,9, W_{min}: 0,4, Ağırlık:2,05
3	CORE	Populasyon Büyüklüğü: 100, Alt Pop. Büyüklüğü: 50, Maks. Jenerasyon Sayısı: 100, Alt Pop. Sayısı: 15, Çaprazlama Oranı: 0,9, Mutasyon Olasılığı: 0,3, Tekrar Üretme Olasılığı: 0,5
4	SIA	İterasyon Sayısı: 200, α: 150, β: 0, Strength Eşik Değeri: 0
5	PGIRLA	Maks. Jenerasyon Sayısı: 5000, Pop. Büyüklüğü: 61, Çapr. Oranı: 0,7, Mut. Olasılığı: 0,5, Araştırılan Kural Sayısı: 20
6	HIDER	Pop. Büyüklüğü: 100, Jen. Limiti: 100, Çapr. Oranı: 0,8, Mut. Olasılığı: 0,5, Extra Mut. Olasılığı: 0,05, Eleme Katsayısı: 0,05, Ceza Puanı: 1, Hata Katsayısı: 0
7	C4.5	Güven Aralığı: 0,25, Dal Başına Min Örnek Sayısı: 2 Eşik: 10

başarı sırasını ifade etmektedir. Tabloların alt satırında ise her bir algoritmanın sonuç ortalaması verilmektedir.

Eğitim doğruluğu ortalaması tablosu incelendiğinde, ABCMiner algoritmasının 50 farklı eğitim işlemi sonucu elde edilen eğitim doğruluğu karşılaştırmasında diğer algoritmalar arası genel sıralamada 4. sırada kalan ortalama bir başarı elde ettiği görülmektedir. Standart sapma değerlerine bakıldığında ise ortalama %1,58 standart sapma ile genel sıralamada yine 4. sırada yer almıştır. SIA algoritması eğitim sırasında eğitim veri kümelerini %100 doğru karşılayan modeller geliştirmiştir.

Test ortalamaları incelendiğinde ABCMiner algoritması kimi problemde en yüksek başarı gösterirken bir çok problemde diğer algoritmalara göre düşük performans göstermiştir. Eğitimde birinci ve ikinci olan SIA ve HIDER algoritmaları aşırı öğrenme gerçekleştirdiği için test doğrulukları karşılaştırmasında C4.5 algoritmasının gerisine düşmüştür. LDWPSO algoritması popülasyon çözümlerinin ABCMiner'da olduğu gibi aynı biçimde kodlandığı bir algoritmadır. ABCMiner algoritması LDWPSO algoritmasından daha düşük standart sapma ile doğru sonuçlar elde edebilmiştir.

Tablo 2.6 ve 2.7'de algoritmaların elde ettikleri sınıflandırma modellerindeki kural ve koşul sayıları verilmiştir. ABCMiner algoritması elde ettiği kural sayıları bakımından diğer algoritmalara göre oldukça basit modeller geliştirmiş ve genel sıralamada birinci

Tablo 2.2. Ortalama eğitim doğrulukları tablosu.

Veri Kümeleri	ABCMiner	C4.5	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	81,51% (5)	93,18% (3)	84,22% (4)	51,00% (7)	**100,00% (1)**	54,48% (6)	95,64% (2)
Taşıtlar	69,46% (4)	71,26% (3)	65,41% (5)	59,03% (6)	**100,00% (1)**	56,20% (7)	82,99% (2)
Soya Fasülyesi	65,53% (5)	81,89% (3)	66,03% (4)	21,05% (7)	**98,47% (1)**	52,91% (6)	91,03% (2)
Hayvanat Bahçesi	94,18% (6)	98,57% (3)	94,80% (5)	99,78% (2)	**100,00% (1)**	93,81% (7)	96,04% (4)
Mantar	94,06% (7)	99,82% (2)	94,12% (6)	98,93% (3)	**99,97% (1)**	97,42% (4)	95,83% (5)
Monkun problemi 2	97,23% (3,5)	**100,00% (1)**	92,48% (6)	97,95% (2)	62,22% (7)	97,07% (5)	97,23% (3,5)
Süsen Çiçeği	98,01% (4)	97,39% (5)	97,27% (7)	98,05% (3)	**100,00% (1)**	98,26% (2)	97,31% (6)
Diyabet	80,43% (2)	77,63% (6)	78,41% (4)	78,83% (3)	**100,00% (1)**	78,02% (5)	75,27% (7)
Hepatit	92,06% (4)	89,47% (7)	91,15% (6)	91,21% (5)	**98,79% (1)**	98,06% (2)	94,15% (3)
Meme Kanseri	77,79% (4)	74,57% (7)	77,55% (5)	80,51% (3)	**97,36% (1)**	80,59% (2)	75,93% (6)
Wisconsin Meme K.	97,20% (4)	97,48% (3)	96,71% (6)	97,91% (2)	**99,84% (1)**	97,11% (5)	96,46% (7)
Yeni Tiroid	98,23% (2)	96,99% (4)	96,50% (5)	97,74% (3)	**100,00% (1)**	96,22% (6)	94,38% (7)
Lenf Grafisi	84,41% (4)	89,64% (2)	83,96% (6)	89,10% (3)	**100,00% (1)**	84,06% (5)	81,15% (7)
Ortalama	86,93% (4)	89,84% (3)	86,05% (5)	81,62% (7)	**96,67% (1)**	83,40% (6)	90,26% (2)

Tablo 2.3. Eğitim doğruluğu standart sapma değerleri tablosu.

Veri Kümeleri	ABCMiner	C4.5	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	4,03% (6)	2,95% (4)	3,77% (5)	1,31% (3)	**0,00% (1)**	12,94% (7)	0,44% (2)
Taşıtlar	2,17% (4)	1,77% (3)	3,87% (6)	5,52% (7)	**0,00% (1)**	3,87% (5)	1,30% (2)
Soya Fasülyesi	4,19% (4)	4,40% (5)	6,60% (7)	5,19% (6)	**0,73% (1)**	3,38% (3)	0,83% (2)
Hayvanat Bahçesi	0,83% (4)	0,53% (2)	0,97% (5)	0,54% (3)	**0,00% (1)**	2,34% (7)	1,78% (6)
Mantar	1,36% (5)	**0,04% (1)**	1,07% (4)	0,42% (3)	0,05% (2)	1,57% (6)	1,84% (7)
Monkun problemi 2	0,28% (2,5)	**0,00% (1)**	8,46% (7)	1,20% (5)	3,61% (6)	1,14% (4)	0,28% (2,5)
Süsen Çiçeği	0,32% (2)	0,54% (5)	1,10% (7)	0,49% (3)	**0,00% (1)**	0,61% (6)	0,49% (4)
Diyabet	1,09% (6)	2,96% (7)	1,03% (4)	0,61% (2)	**0,00% (1)**	0,82% (3)	1,03% (5)
Hepatit	1,58% (4)	2,60% (7)	1,92% (5)	**0,97% (1)**	1,09% (3)	1,09% (2)	2,11% (6)
Meme Kanseri	1,54% (6)	1,22% (4)	1,47% (5)	**0,62% (1)**	0,72% (2)	0,83% (3)	1,88% (7)
Wisconsin Meme K.	0,24% (3)	0,53% (5)	0,68% (6)	0,22% (2)	**0,11% (1)**	0,53% (4)	1,43% (7)
Yeni Tiroid	0,81% (3)	1,98% (7)	1,05% (5)	0,81% (4)	**0,00% (1)**	0,70% (2)	1,27% (6)
Lenf Grafisi	2,15% (3)	3,76% (7)	3,01% (6)	1,68% (2)	**0,00% (1)**	2,28% (4)	2,50% (5)
Ortalama	1,58% (4)	1,79% (5)	2,69% (7)	1,51% (3)	**0,48% (1)**	2,47% (6)	1,32% (2)

olmuştur. Koşul sayısı bakımından değerlendirildiğinde ise LDWPSO algoritmasından sonra çok az bir farkla ikinci sırada yer almaktadır. Aşırı öğrenme gerçekleştiren SIA algoritmasının ortaya koyduğu modeller ABCMiner ile elde edilen modellere göre karşılaştırılamayacak derecede karmaşıktır. ABCMiner algoritması sahip olduğu sadeleştirme yaklaşımları ve çözüm araştırmasında kullanılan kalite değerlendirme fonksiyonundan dolayı daha kısa ve sade kural kümesi geliştirmektedir. ABCMiner ile deneylerde kullanılan problemler için yeterli doğruluğa sahip çok daha basit sınıflandırma modelleri geliştirilmiştir.

Tablo 2.8'de algoritmaların eğitimleri için geçen ortalama süreler verilmektedir. Sonuçlar değerlendirildiğinde C4.5 algoritması aç gözlü yaklaşım gerçekleştirdiği için diğer meta-sezgisel algoritmalara göre en kısa sürede model öğrenimi gerçekleştirmiştir. ABCMiner algoritması diğer meta-sezgisel algoritmalarda olduğu gibi çok fazla sayıda çözüm denemesi yaptığı için değerlendirme süreleri fazla olmaktadır.

Tablo 2.4. Ortalama test doğrulukları tablosu.

Veri Kümeleri	ABCMiner	C4.5	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	69,62% (3)	**77,26% (1)**	67,15% (4)	47,10% (5)	74,46% (2)	45,20% (6)	14,83% (7)
Taşıtlar	48,30% (7)	**66,54% (1)**	50,28% (6)	57,03% (4)	62,42% (2)	52,56% (5)	59,81% (3)
Soya Fasülyesi	64,45% (5)	78,34% (3)	65,30% (4)	20,67% (7)	**90,34% (1)**	51,39% (6)	85,91% (2)
Hayvanat Bahçesi	90,89% (5)	94,00% (2)	91,05% (4)	93,44% (3)	**95,20% (1)**	88,07% (7)	90,27% (6)
Mantar	90,49% (7)	99,83% (2)	93,52% (6)	98,89% (3)	**99,98% (1)**	97,39% (4)	95,72% (5)
Monkun problemi 2	97,27% (3,5)	**100,00% (1)**	92,09% (6)	97,66% (2)	62,51% (7)	95,69% (5)	97,27% (3,5)
Süsen Çiçeği	92,78% (6)	**96,66% (1)**	91,86% (7)	95,32% (3)	95,32% (4)	95,19% (5)	95,98% (2)
Diyabet	65,94% (7)	71,73% (3)	69,59% (6)	**74,35% (1)**	71,41% (4)	73,13% (2)	70,91% (5)
Hepatit	76,70% (7)	83,93% (2)	76,76% (6)	81,16% (4)	78,58% (5)	**90,36% (1)**	81,76% (3)
Meme Kanseri	75,12% (2)	71,43% (6)	**75,27% (1)**	73,62% (4)	70,04% (7)	72,31% (5)	74,69% (3)
Wisconsin Meme K.	**96,08% (1)**	95,28% (7)	95,70% (4)	95,73% (3)	96,02% (2)	95,51% (5)	95,30% (6)
Yeni Tiroid	78,94% (7)	90,32% (5)	80,42% (6)	93,42% (2)	**94,62% (1)**	90,94% (3)	90,46% (4)
Lenf Grafisi	64,82% (7)	77,93% (3)	68,78% (6)	78,82% (2)	**81,71% (1)**	75,85% (4)	73,37% (5)
Ortalama	77,80% (6)	**84,87% (1)**	78,29% (5)	77,48% (7)	82,51% (2)	78,74% (4)	78,94% (3)

Tablo 2.5. Test doğruluğu standart sapma değerleri tablosu.

Veri Kümeleri	ABCMiner	C4.5	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	15,36% (6)	12,05% (2)	18,72% (7)	**3,03% (1)**	14,27% (4)	14,50% (5)	13,36% (3)
Taşıtlar	8,37% (7)	5,07% (2)	7,28% (5)	7,68% (6)	5,56% (4)	5,40% (3)	**4,72% (1)**
Soya Fasülyesi	5,80% (6)	4,47% (2)	8,01% (7)	5,49% (5)	**2,86% (1)**	4,99% (4)	4,55% (3)
Hayvanat Bahçesi	8,04% (5)	6,99% (2)	9,74% (7)	7,16% (3)	7,62% (4)	8,59% (6)	**6,55% (1)**
Mantar	11,40% (7)	0,20% (2)	3,08% (6)	0,51% (3)	**0,05% (1)**	1,54% (4)	1,91% (5)
Monkun problemi 2	2,67% (2,5)	**0,00% (1)**	9,22% (7)	2,75% (4)	5,81% (5)	7,35% (6)	2,67% (2,5)
Süsen Çiçeği	4,82% (5)	4,71% (4)	4,51% (3)	4,90% (6)	4,31% (2)	5,40% (7)	**3,82% (1)**
Diyabet	5,31% (7)	**3,80% (1)**	5,02% (6)	4,02% (2)	4,42% (5)	4,12% (3)	4,30% (4)
Hepatit	9,37% (4)	10,49% (7)	9,23% (2)	9,30% (3)	**8,66% (1)**	10,24% (5)	10,32% (6)
Meme Kanseri	**4,95% (1)**	7,35% (5)	5,08% (2)	5,89% (3)	7,36% (6)	7,15% (4)	8,00% (7)
Wisconsin Meme K.	**1,79% (1)**	2,02% (3)	2,45% (5)	1,81% (2)	2,35% (4)	3,09% (6)	4,00% (7)
Yeni Tiroid	14,24% (7)	5,80% (3)	13,13% (6)	4,81% (2)	**4,04% (1)**	7,06% (5)	6,48% (4)
Lenf Grafisi	16,91% (7)	12,07% (4)	15,82% (6)	11,78% (2)	12,03% (3)	12,10% (5)	**8,83% (1)**
Ortalama	8,39% (6)	5,77% (2)	8,56% (7)	**5,32% (1)**	6,10% (3)	7,04% (5)	6,12% (4)

Tablo 2.9'da algoritmaların elde ettiği sonuçların birbiri ile yapılan orta değere dayalı karşıtlık değerleri istatistik karşılaştırılması verilmiştir [133]. Tabloda gösterilen negatif değerler satırda verilen algoritmanın sütunda verilen algoritmaya göre daha düşük orta değer elde ettiğini ifade etmektedir. Karşılaştırmada C4.5 algoritması 13 farklı problemin her biri için elde edilen 50 farklı deney sonucuna göre en başarılı algoritma olduğu görülmektedir. CORE ve SIA algoritmaları LDWPSO, PGIRLA ve HIDER algoritmalarına göre daha üstün olduğu görülmektedir. Tabloda görüldüğü üzere ABCMiner, LDWPSO algoritması ile çok yakın bir değer elde etmiştir.

Tablo 2.6. Sınıflandırma modellerinin ortalama kural sayıları tablosu.

Veri Kümeleri	ABCMiner	C4.5	LDWPSO	CORE	SIA	HIDER
E.Coli Gen Dizisi	7,6 (3)	9,3 (4)	6,5 (2)	**2,5 (1)**	29,1 (5)	71,6 (6)
Taşıtlar	**8,0 (1)**	18,3 (4)	8,3 (2)	10,3 (3)	687,2 (6)	46,2 (5)
Soya Fasülyesi	16,3 (2)	39,1 (5)	17,1 (3)	**8,7 (1)**	83,9 (6)	20,1 (4)
Hayvanat Bahçesi	**6,0 (1)**	7,7 (4)	6,6 (3)	8,1 (5)	9,9 (6)	6,2 (2)
Mantar	**3,9 (1)**	16,3 (5)	4,3 (2)	9,4 (4)	24,5 (6)	4,7 (3)
Monkun problemi 2	**2,0 (1,5)**	5,0 (5)	2,3 (3)	3,8 (4)	17,7 (6)	**2,0 (1,5)**
Süsen Çiçeği	**3,0 (1,5)**	4,0 (4)	3,2 (3)	4,5 (5)	14,4 (6)	**3,0 (1,5)**
Diyabet	**5,3 (1)**	8,7 (3)	5,6 (2)	9,2 (4)	599,2 (6)	9,7 (5)
Hepatit	4,4 (2)	6,6 (4)	4,6 (3)	7,8 (5)	70,4 (6)	**4,2 (1)**
Meme Kanseri	5,5 (3)	12,5 (5)	5,3 (2)	8,2 (4)	88,5 (6)	**2,7 (1)**
Wisconsin Meme K.	**2,2 (1)**	10,2 (5)	2,6 (3)	6,8 (4)	40,4 (6)	2,2 (2)
Yeni Tiroid	4,0 (2,5)	5,6 (4)	4,0 (2,5)	6,4 (5)	41,8 (6)	**3,3 (1)**
Lenf Grafisi	5,3 (2)	11,3 (5)	5,6 (3)	11,0 (4)	32,8 (6)	**3,2 (1)**
Ortalama	**5,66 (1)**	11,89 (4)	5,85 (2)	7,44 (3)	133,84 (6)	13,77 (5)

Tablo 2.7. Sınıflandırma modellerinin ortalama koşul sayıları tablosu.

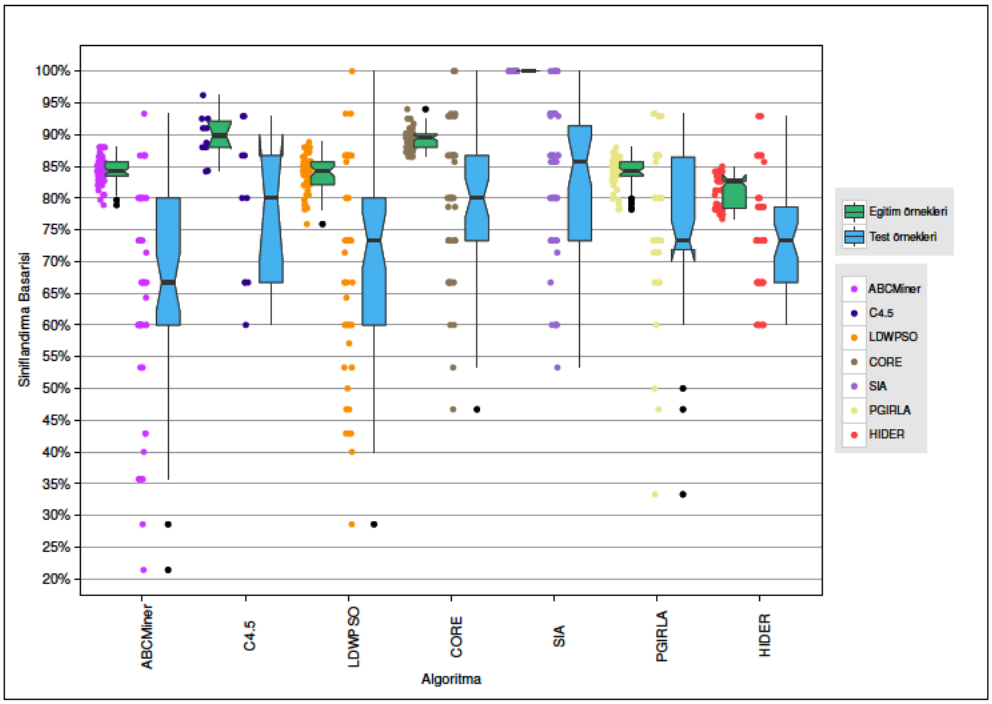
Veri Kümeleri	ABCMiner	C4.5	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	6,68 (2)	14,1 (3)	**5,68 (1)**	37,56 (4)	70,2 (5)	620,4 (6)	1363,62 (7)
Taşıtlar	34,82 (3)	34,5 (2)	**29,54 (1)**	44,1 (4)	12189,88 (7)	146,66 (5)	801,96 (6)
Soya Fasülyesi	**38,74 (1)**	146,6 (4)	43,78 (2)	89,94 (3)	755,44 (7)	409,3 (6)	176,82 (5)
Hayvanat Bahçesi	**6,72 (1)**	18,2 (4)	7,46 (2)	43,1 (5)	49,82 (6)	160,98 (7)	9,46 (3)
Mantar	**5,5 (1)**	31,7 (3)	6,18 (2)	46,04 (4)	80,18 (6)	212,62 (7)	73,38 (5)
Monkun problemi 2	**2,0 (1,5)**	5,0 (5)	2,04 (3)	4,84 (4)	75,82 (7)	45,82 (6)	2,0 (1,5)
Süsen Çiçeği	3,12 (2)	**2,7 (1)**	3,14 (3)	7,4 (5)	45,12 (7)	31,16 (6)	6,64 (4)
Diyabet	18,38 (3)	13,3 (2)	**12,24 (1)**	24,3 (4)	4412,78 (7)	63,12 (5)	71,44 (6)
Hepatit	12,56 (3)	11,1 (2)	**10,24 (1)**	38,86 (5)	690,0 (7)	197,1 (6)	25,86 (4)
Meme Kanseri	7,08 (2)	40,8 (5)	**6,88 (1)**	19,32 (4)	363,04 (7)	77,12 (6)	9,5 (3)
Wisconsin Meme K.	6,12 (2)	8,3 (4)	**5,74 (1)**	19,88 (5)	168,78 (7)	66,4 (6)	6,62 (3)
Yeni Tiroid	6,88 (3)	5,8 (2)	**5,74 (1)**	15,0 (4)	185,9 (7)	35,84 (6)	15,34 (5)
Lenf Grafisi	**9,22 (1)**	23,1 (4)	10,28 (2)	52,36 (5)	140,88 (6)	175,0 (7)	10,82 (3)
Ortalama	12,14 (2)	27,32 (3)	**11,46 (1)**	34,05 (4)	1479,06 (7)	172,42 (5)	197,96 (6)

Tablo 2.8. Algoritmaların ortalama çalışma süreleri tablosu.

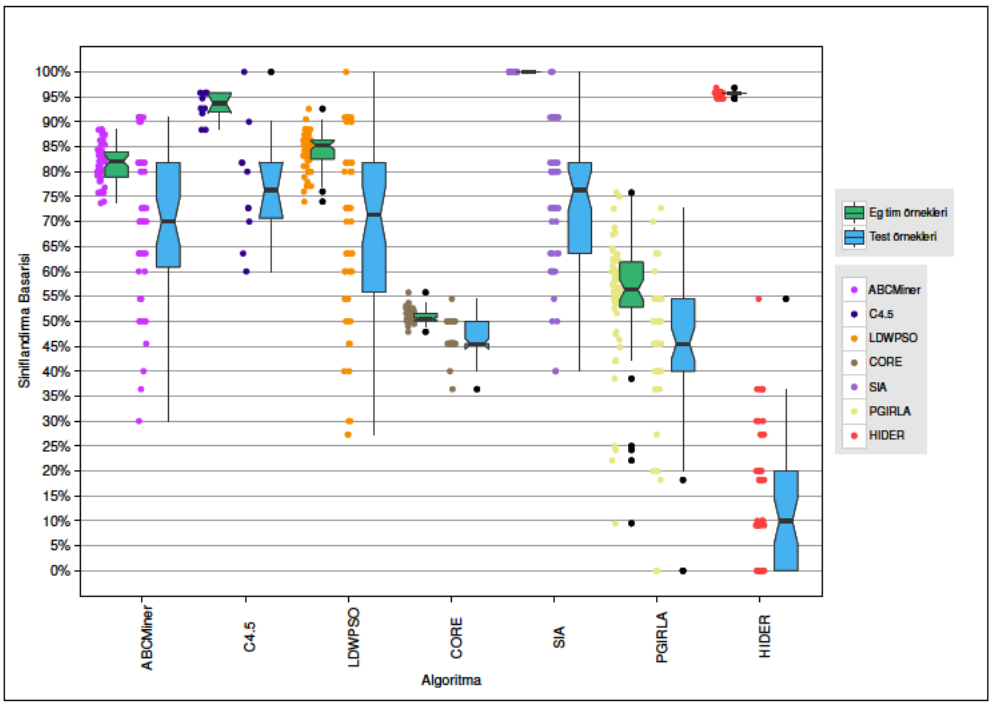
Veri Kümeleri	C4 5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E Coli Gen Dizisi	**300 (1)**	885 144 (6)	2 019 790 (7)	57 280 (4)	2 920 (3)	1 500 (2)	144 600 (5)
Taştlar	**1 200 (1)**	25 378 (3)	78 357 (5)	171 548 (7)	102 760 (6)	3 200 (2)	61 500 (4)
Soya Fasülyesi	**800 (1)**	5 918 583 (6)	10 039 326 (7)	290 785 (5)	19 500 (3)	4 600 (2)	40 700 (4)
Hayvanat Bahçesi	**280 (1)**	30 327 (6)	157 195 (7)	29 659 (5)	1 000 (3)	900 (2)	3 500 (4)
Mantar	**1 500 (1)**	12 679 894 (6)	18 620 857 (7)	3 742 910 (5)	1 979 920 (4)	20 400 (2)	96 300 (3)
Monkun Problemi 2	**100 (1)**	5 167 (5)	7 943 (6)	45 459 (7)	1 000 (2)	1 300 (3)	4 000 (4)
Süsen Çiçeği	**200 (1)**	2 906 (5)	7 246 (6)	22 127 (7)	920 (3)	850 (2)	1 500 (4)
Diyabet	**600 (1)**	46 283 (4)	66 154 (6)	93 285 (7)	52 960 (5)	2 500 (2)	7 100 (3)
Hepatit	**460 (1)**	195 179 (6)	344 093 (7)	30 609 (5)	2 200 (3)	960 (2)	3 200 (4)
Meme Kanseri	**400 (1)**	137 526 (6)	202 091 (7)	32 489 (5)	3 620 (4)	1 400 (2)	3 200 (3)
Wisconsin Meme K	**500 (1)**	8 845 (5)	16 890 (6)	97 207 (7)	7 040 (4)	2 200 (2)	4 400 (3)
Yeni Tiroid	**250 (1)**	4 672 (5)	8 065 (6)	30 433 (7)	1 000 (3)	880 (2)	1 900 (4)
Lenf Grafisi	**380 (1)**	227 646 (6)	426 217 (7)	40 298 (5)	1 440 (3)	1 100 (2)	3 600 (4)
Ortalama	**536 (1)**	1 551 350 (6)	2 461 094 (7)	360 314 (5)	167 406 (4)	3 214 (2)	28 884 (3)

Tablo 2.9. Algoritmaların test doğrulukları için orta degere dayalı karşıtlık değerleri tablosu (contrast estimation based on medians) [133].

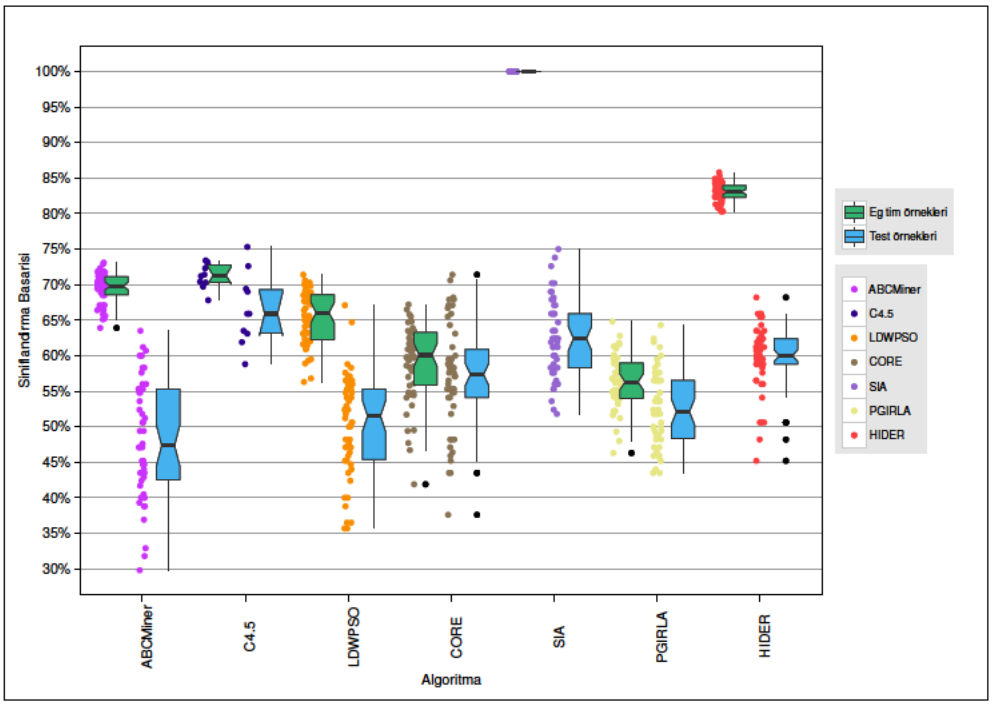
	C4.5	LDWPSO	CORE	SIA	PGIRLA	HIDER
ABCMiner	-0,064	-0,003	-0,047	-0,057	-0,036	-0,04
C4.5		**0,061**	**0,017**	**0,007**	**0,028**	**0,024**
LDWPSO			-0,044	-0,054	-0,033	-0,036
CORE				-0,01	**0,011**	**0,007**
SIA					**0,021**	**0,017**
PGIRLA						-0,004



Şekil 2.4. Lenf grafisi için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafiği.

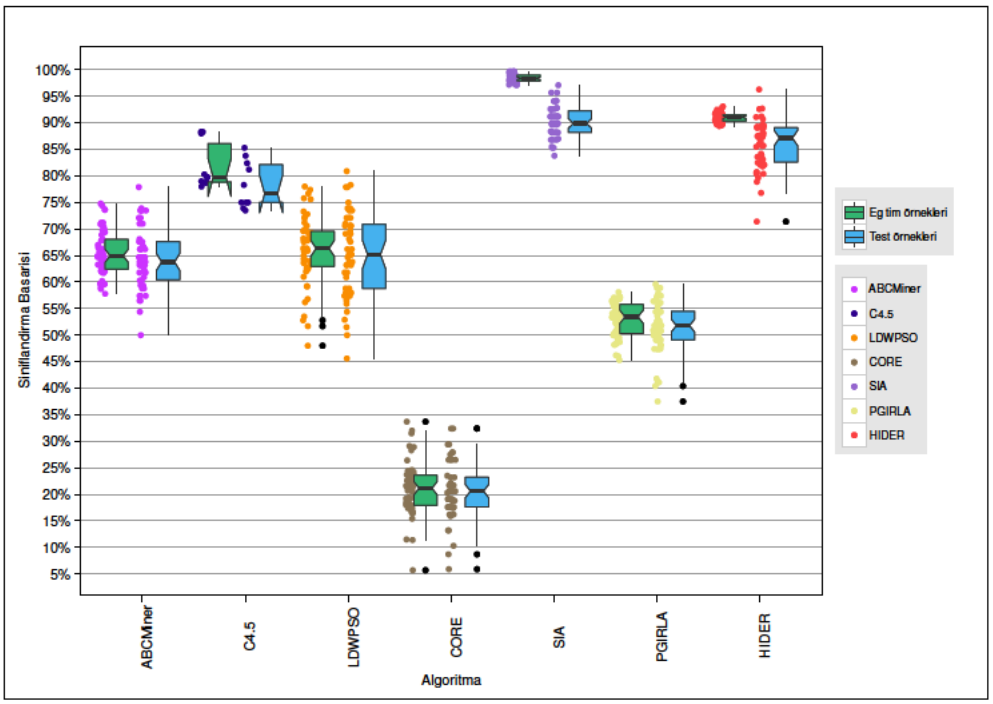


(a) E.Coli Gen Dizisi

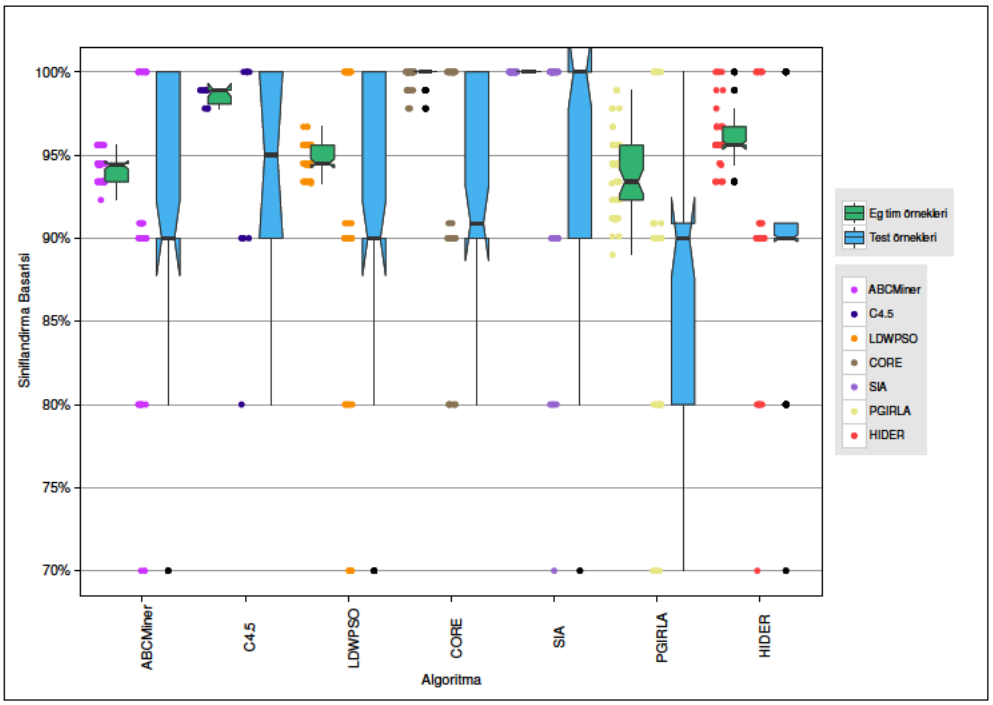


(b) Taşıtlar

Şekil 2.5. E.coli gen dizisi ve taşıtlar için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri.

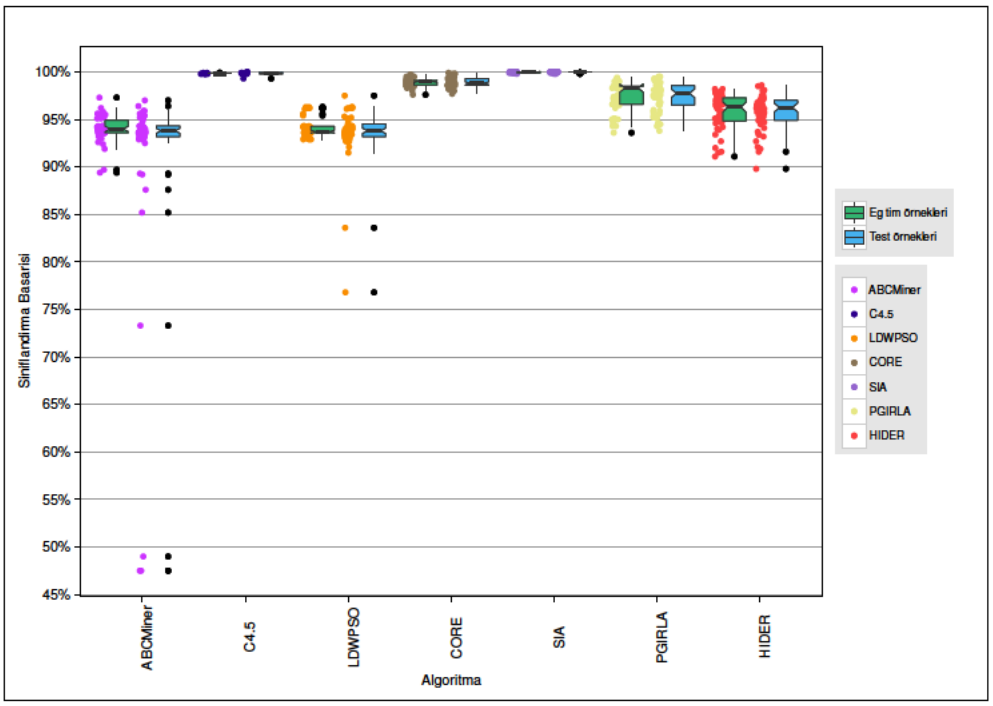


(a) Soya Fasülyesi

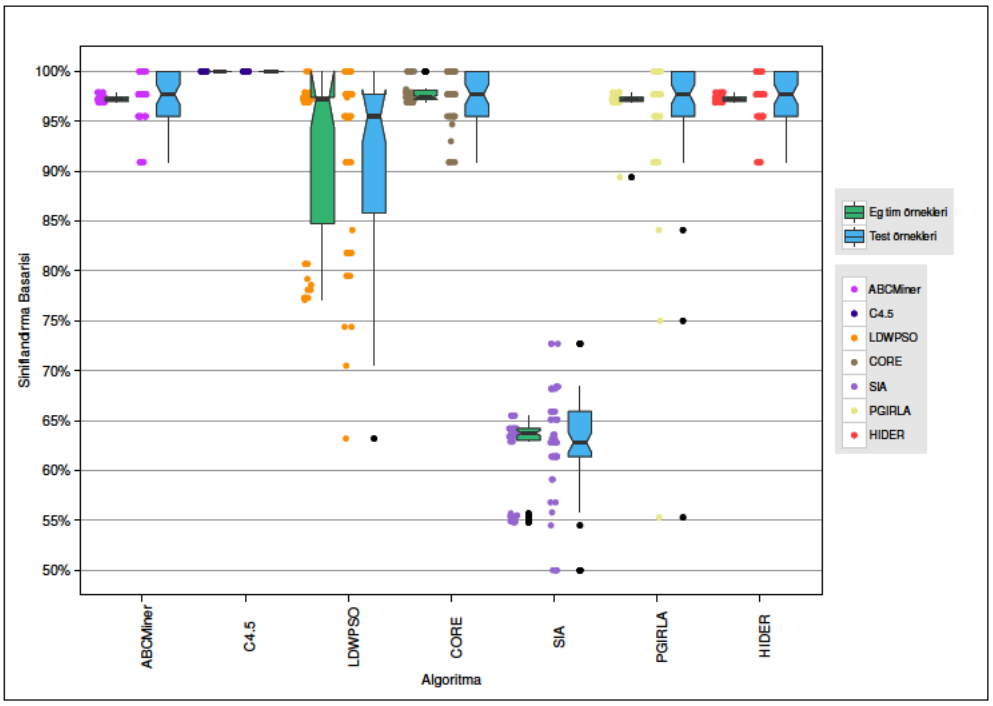


(b) Hayvanat Bahçesi

Şekil 2.6. Soya fasülyesi ve hayvanat bahçesi için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri.

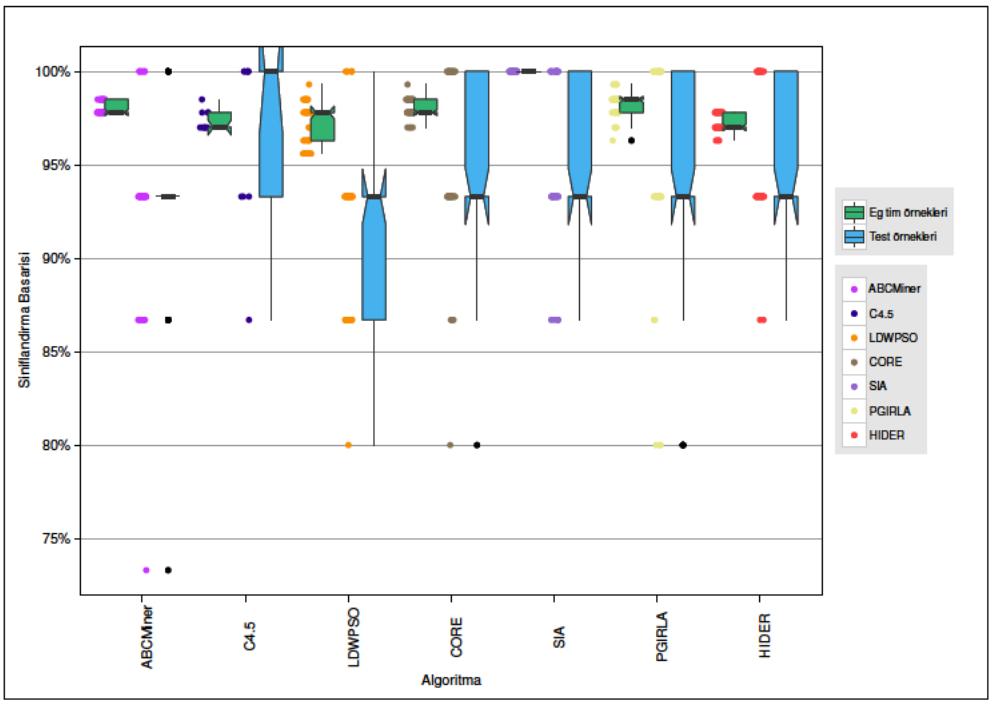


(a) Mantar

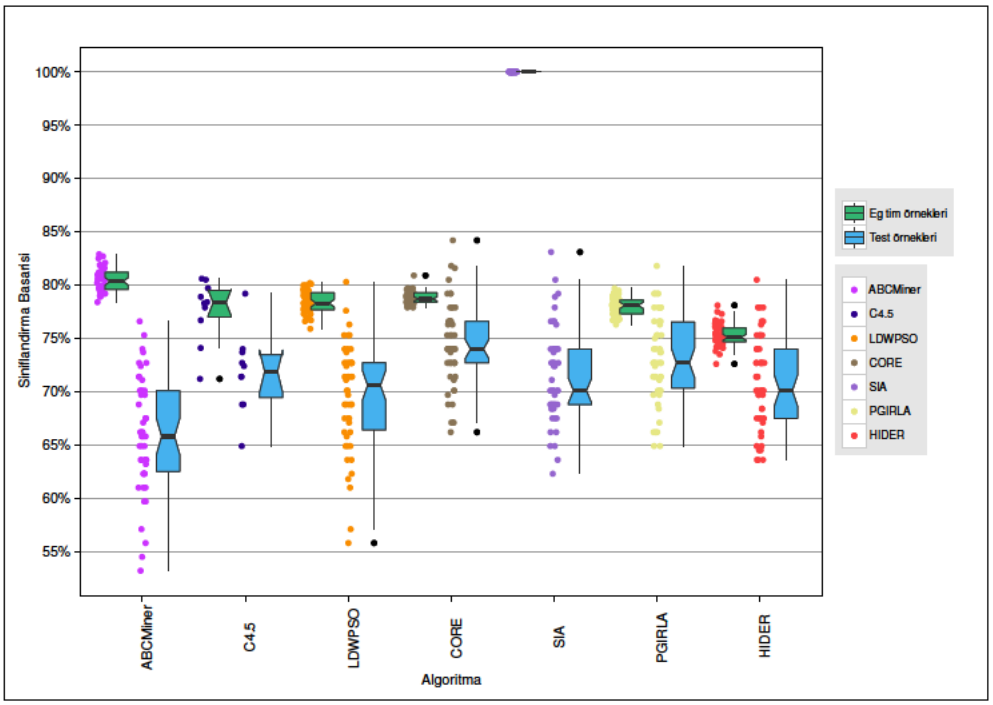


(b) Monkun problemi 2

Şekil 2.7. Mantar ve monkun problemi 2 için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri.

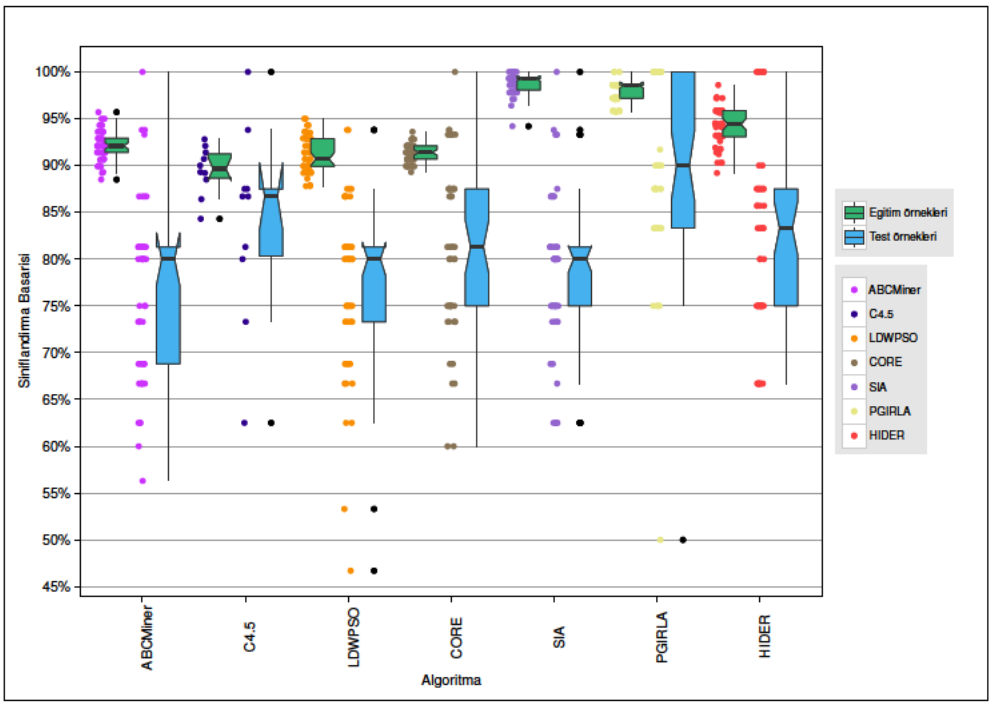


(a) Süsen Çiçeği

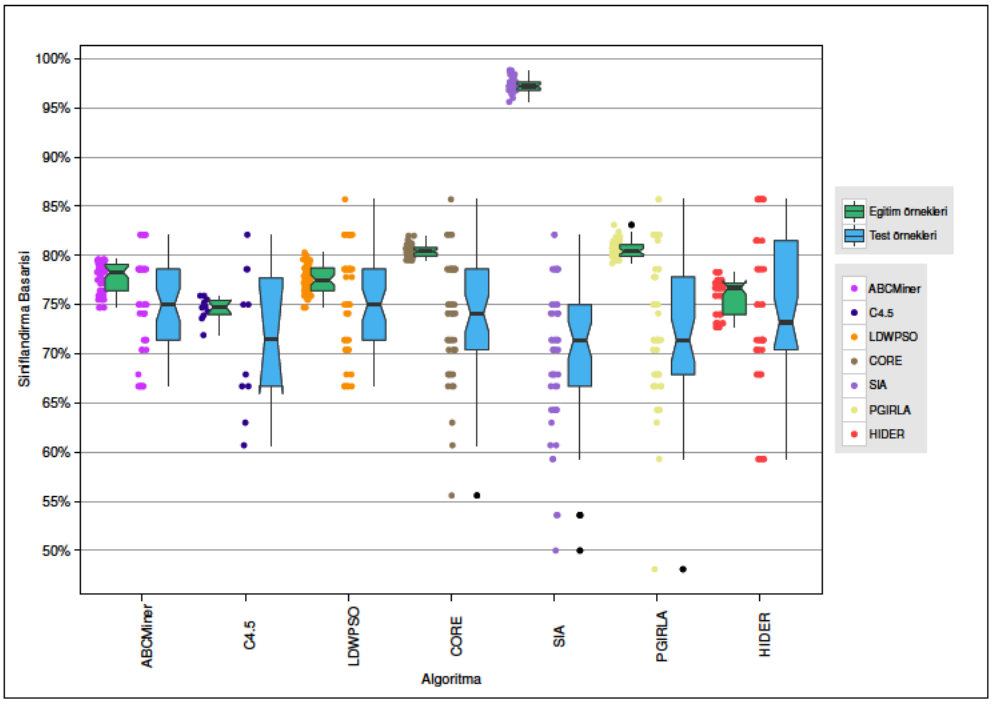


(b) Diyabet

Şekil 2.8. Süsen çiçeği ve diyabet için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri.

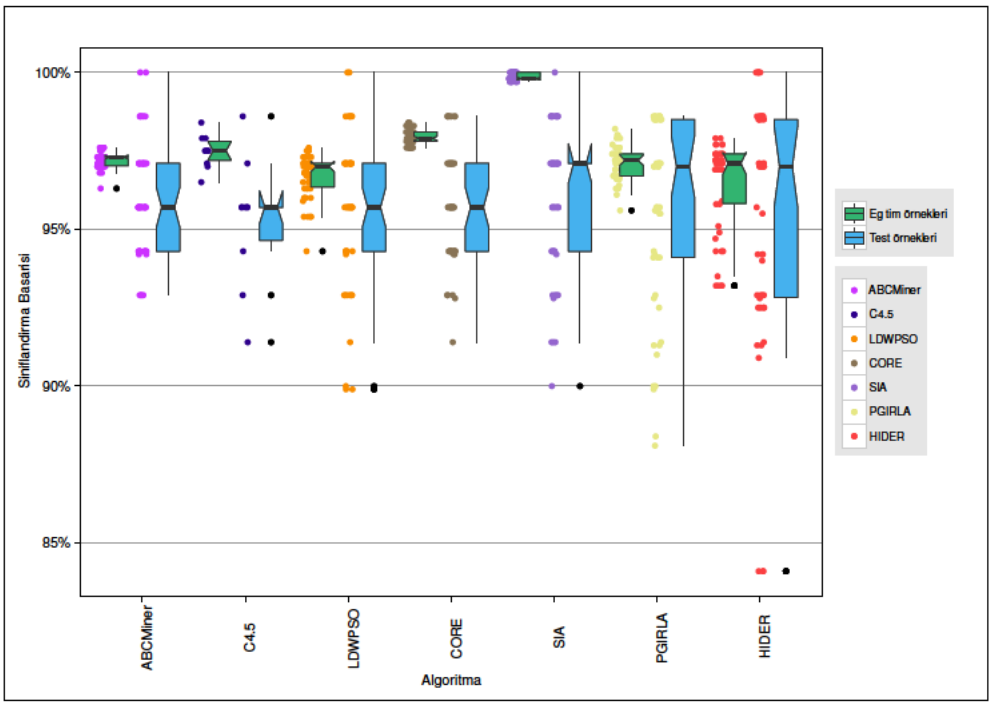


(a) Hepatit

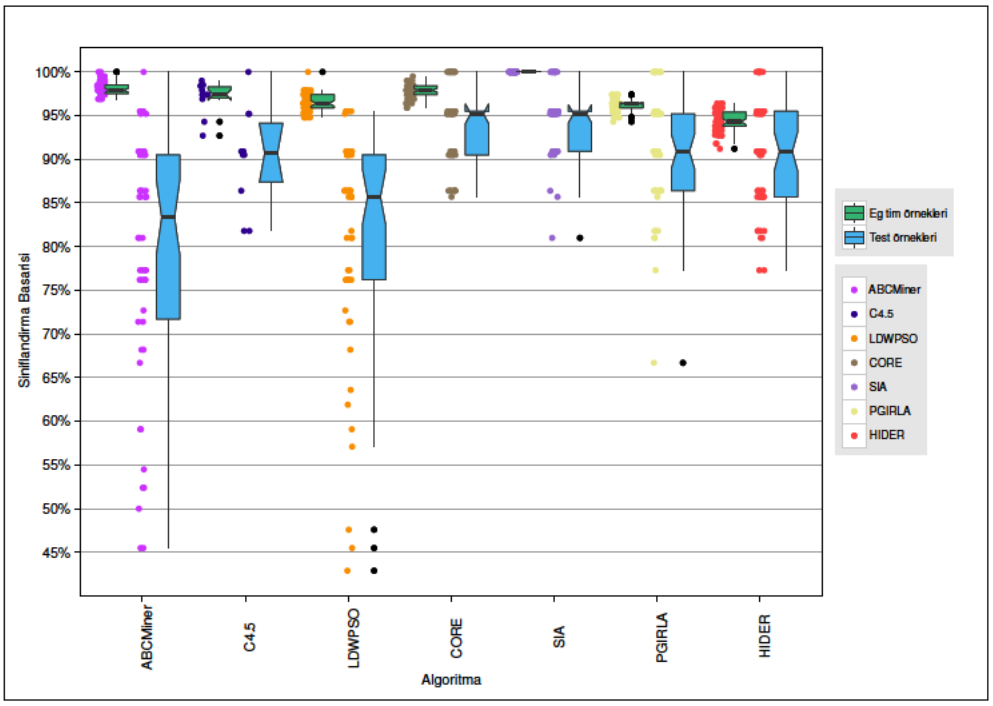


(b) Kanser

Şekil 2.9. Hepatit ve meme kanseri için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri.



(a) Wisconsin Meme K.



(b) Yeni Tiroid

Şekil 2.10. Wisconsin meme kanseri ve yeni tiroid için algoritmaların elde ettiği eğitim ve test başarısı kutu ve saçılım grafikleri.

2.3.2. ABCMiner Algoritmasının Dengesiz Sınıf Dağılımlı Test Problemleri Üzerindeki Doğruluk Analizi

ABCMiner algoritması, detayları EK-1'de verilen dengesiz sınıf dağılımına sahip 33 test problemi üzerinde de değerlendirilmiş ve diğer algoritmalar ile karşılaştırılmıştır. Dengesiz dağılımlı problemler, veri kümesinde her sınıf için yeterli ve eşit sayıda eğitim örneği içermemektedir. Bazı algoritmalar bu tür veri kümesi karşısında her bir sınıfı aynı yüksek doğrulukla öğrenemediğinden dolayı sınıflandırma modeli yetersiz kalmakta dolayısıyla algoritma başarısız olabilmektedir. Elde edilen deney sonuçları literatürde daha önce yapılmış çalışmada yer alan 16 sınıflandırma algoritmasının sonuçları ile karşılaştırılmıştır [60]. ABCMiner algoritması 5 ayrı rastgele başlangıç popülasyonu kullanılarak 5 kat çapraz doğrulama işlemi ile 25 kez çalıştırılmıştır ve elde edilen doğrulukların ortalaması alınmıştır. Diğer algoritmalara ait sonuçlar ise 5 kat çapraz doğrulama yöntemi ile elde edilen 5 çalıştırmaya ait sonuçların ortalamasıdır. Elde edilen eğitim ve test doğruluk değerleri Tablo 2.10, 2.11, 2.12 ve 2.13'te verilmiştir. Bazı problemler için sonuçlar elde edilememiş ve tablolarda (-) ile verilmiştir ve karşılaştırmalar diğer algoritmalar arasında yapılmıştır.

Tablo 2.10 ve 2.11'de görüldüğü üzere ABCMiner algoritması veri kümeleri için 17 algoritma içinde, ObliqueDT ve SIA algoritmalarından sonra 3,64 ortalama derecesi ile eğitim doğruluğu karşılaştırmasında üçüncü algoritma olmuştur. ObliqueDT ve SIA algoritmaları model geliştirilmesinde aşırı öğrenme davranışı göstermiş bir çok problemi %100 doğruluk oranıyla öğrenmiştir. Sonuçlardan da görüleceği üzere ABCMiner, 12 problem üzerinde algoritmaları geride bırakmış ve ObliqueDT ve SIA'dan sonra ikinci sırada yer almıştır. Maya1, Cam6, Cam2, Abalone9vs18 problemleri için sonuçlar incelendiğinde ABCMiner algoritması kendinden sonra gelen algoritmaya oranla belirgin bir doğruluk elde etmiştir. Maya1 sonuçları incelendiğinde ABCMiner %77,22 ile ikinci, UCS %74,58 ile üçüncü olmuştur. ABCMiner Cam6 veri kümesinde %99,02 başarı oranı elde etmiş, bir sonraki algoritma PGIRLA ise %98,70 oran elde etmiştir. ABCMiner algoritması Cam2 için %94,72 başarı oranı elde etmiş sonraki OCEC algoritması %83,89 gibi daha düşük bir oranda kalmıştır. Abalone9vs18 veri kümesinde ise ABCMiner

%95,12 oranıyla ikinci algoritma iken üçüncü sıradaki OCEC %69,77 oranında kalmıştır.

Sınıflandırma sisteminin yeni durumlar karşısında elde ettiği tahmin başarısını içeren test sonuçları algoritmayı değerlendirmek için eğitim sonuçlarından daha çok önem arzeder. Tablo 2.12 ve Tablo 2.13'te dengesiz veri kümeleri üzerinde elde edilen test doğrulukları verilmiştir. Tablolar incelendiğinde ABCMiner algoritmasının problemler üzerinde diğer algoritmalara karşı elde ettiği başarı açık bir şekilde görülmektedir.

ABCMiner algoritması; Maya1, Taşıtlar1, Taşıtlar3, Haberman, Ecoli2, Maya3, Ecoli3, Cam2, Ecoli4, Abalone9vs18, Maya2vs8, Maya4, Maya5, Maya6 ve Abalone19 veri kümeleri olmak üzere 15 problem için test doğruluğu açısından birinci olmuştur. ABCMiner 17 algoritma arasında 11. olduğu Ecoli0vs1, Yeni Tiroit2 ve Segmentasyon0 veri kümelerinde en düşük performansını göstermiştir. Tablolardan görüldüğü üzere ABCMiner algoritması 33 problem için ortalama 3,91 sıralama derecesi ile eğitim doğrulukları daha yüksek olan ObliqueDT ve SIA algoritmalarını geride bırakmış ve test problemleri açısından en yüksek ortalama derecesine sahip olan birinci algoritma olmuştur. ObliqueDT %100 ile öğrendiği veri kümelerinden sadece Cam5 veri kümesi için %93,65 test oranı ile diğer algoritmalara göre birinci olmuştur. SIA algoritması 27 veri kümesinde en yüksek eğitim başarısı göstermesine rağmen Süsen0, Segmentasyon0, Vowel0 ve Cam4 olmak üzere sadece 4 dengesiz veri kümesi için sırasıyla %100; %99,44; %100 ve %95,41 test oranları elde ederek birinci olmuştur. ObliqueDT ve SIA algoritmalarının test başarısında geride kalması, bu algoritmaların aşırı öğrenme karakteristiği göstermesi ve veri için aşırı özelleşmiş sınıflandırma modelleri ortaya koymasından kaynaklanmaktadır.

Tablo 2.10. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde eğitim doğrulukları tablosu.

Veri Kümesi	ABCMiner	COGIN*	CORE*	DMEL*	DT-GA*	Gassist*	GIL*	HIDER*	ILGA*
Cam1	84,53% (5)	60,91% (12)	51,04% (13)	25,00% (16)	71,15% (7)	88,93% (3)	70,00% (9)	86,19% (4)	38,72% (15)
Ecoli0vs1	99,09% (2)	80,93% (11)	98,69% (6)	25,01% (13)	98,69% (6)	98,69% (6)	90,87% (9)	97,52% (8)	98,69% (6)
Wisconsin Meme K	97,35% (8)	98,43% (5)	93,89% (15)	52,88% (17)	97,25% (9)	98,74% (3)	97,52% (7)	97,03% (10)	94,57% (14)
Diyabet	81,20% (3)	38,87% (15)	63,74% (11)	25,16% (16)	78,99% (4)	77,69% (6)	54,52% (14)	71,93% (7)	68,29% (10)
Süsen0	**100,00% (1)**	94,27% (3)	**100,00% (1)**	75,16% (5)	**100,00% (1)**	**100,00% (1)**	94,81% (2)	**100,00% (1)**	**100,00% (1)**
Cam0	88,04% (5)	66,68% (11)	67,93% (10)	-	89,78% (4)	90,66% (3)	78,21% (7)	84,36% (6)	74,42% (9)
Maya1	77,22% (2)	11,46% (15)	47,63% (8)	-	68,32% (4)	66,87% (5)	42,79% (12)	45,66% (9)	41,93% (13)
Taştlar1	81,46% (3)	61,07% (9)	38,03% (13)	5,37% (16)	69,89% (6)	68,57% (8)	68,95% (7)	55,20% (10)	43,31% (12)
Taştlar2	94,79% (7)	88,65% (11)	38,22% (15)	49,51% (14)	97,75% (4)	97,87% (3)	90,22% (10)	81,18% (12)	94,91% (6)
Taştlar3	81,73% (4)	58,08% (9)	18,94% (13)	15,81% (14)	71,92% (6)	70,38% (7)	70,26% (8)	55,31% (10)	45,98% (12)
Haberman	79,08% (3)	21,86% (15)	47,47% (10)	38,08% (14)	40,83% (12)	66,81% (5)	48,87% (9)	41,69% (11)	18,58% (16)
Cam0123vs456	97,27% (5)	88,52% (14)	87,26% (15)	69,50% (16)	92,34% (11)	98,71% (3)	95,39% (7)	97,31% (4)	93,62% (10)
Taştlar0	92,15% (7)	68,72% (13)	19,38% (15)	3,88% (16)	94,52% (4)	95,69% (3)	80,40% (10)	70,25% (12)	86,11% (8)
Ecoli1	94,41% (4)	59,87% (14)	89,88% (9)	18,30% (16)	90,81% (8)	94,60% (3)	69,65% (13)	77,94% (11)	91,28% (6)
Yeni Tiroit2	99,05% (4)	86,20% (15)	94,45% (13)	81,34% (16)	94,85% (10)	98,47% (7)	94,68% (12)	95,16% (9)	98,54% (6)
Yeni Tiroit1	99,42% (4)	83,82% (15)	92,27% (10)	83,57% (16)	96,96% (7)	99,86% (2)	88,46% (14)	95,70% (8)	99,20% (5)
Ecoli2	96,74% (2)	38,05% (15)	79,22% (9)	-	86,92% (7)	96,03% (3)	61,04% (12)	59,29% (13)	91,53% (5)
Segmentasyon0	90,74% (10)	64,34% (13)	-	-	98,99% (6)	99,12% (4)	93,64% (9)	86,94% (11)	98,94% (7)
Cam6	99,02% (2)	96,43% (9)	88,30% (14)	57,08% (15)	93,25% (13)	97,37% (7)	**100,00% (1)**	94,44% (11)	95,57% (10)
Maya3	95,81% (3)	60,15% (13)	72,57% (11)	-	87,28% (9)	90,85% (7)	92,22% (6)	60,01% (14)	67,24% (12)
Ecoli3	94,94% (2)	64,11% (9)	59,86% (12)	7,98% (15)	79,64% (4)	84,06% (3)	72,29% (7)	64,02% (10)	60,74% (11)
Sayfa-Blokları0	94,78% (5)	56,12% (16)	64,31% (14)	0,95% (17)	95,27% (4)	82,93% (8)	75,24% (11)	90,19% (6)	65,31% (13)
Vowel0	97,23% (6)	51,76% (15)	78,74% (10)	18,83% (16)	99,96% (2)	98,87% (4)	70,44% (13)	88,37% (9)	88,92% (8)
Cam2	94,72% (2)	31,54% (7)	21,58% (9)	-	82,65% (5)	7,56% (11)	83,83% (4)	9,17% (10)	-
Ecoli4	98,74% (2)	51,01% (14)	86,63% (9)	8,53% (15)	94,10% (4)	97,44% (3)	88,48% (8)	82,61% (10)	90,79% (7)
Cam4	97,62% (3)	78,70% (7)	68,66% (11)	10,17% (15)	62,19% (13)	95,49% (6)	96,90% (4)	67,95% (12)	72,01% (10)
Abalone9vs18	95,12% (2)	53,60% (8)	37,57% (11)	52,90% (9)	62,76% (5)	62,27% (6)	68,59% (4)	18,83% (15)	32,13% (12)
Cam5	97,99% (3)	84,40% (7)	87,44% (6)	-	63,01% (10)	66,90% (8)	99,20% (2)	61,27% (11)	54,21% (12)
Maya2vs8	96,93% (2)	74,79% (6)	74,01% (8)	25,65% (13)	20,91% (14)	78,21% (5)	84,81% (3)	72,39% (10)	31,21% (12)
Maya4	96,41% (3)	25,44% (11)	16,80% (14)	-	60,82% (7)	36,02% (8)	74,31% (6)	17,30% (13)	34,56% (10)
Maya5	97,17% (2)	46,82% (9)	15,94% (12)	-	85,50% (7)	89,81% (4)	85,87% (6)	8,93% (13)	46,21% (10)
Maya6	97,64% (2)	40,45% (8)	5,34% (11)	-	66,51% (7)	-	71,97% (6)	-	10,33% (9)
Abalone19	99,23% (2)	-	-	7,92% (7)	-	-	81,27% (5)	-	-
Sıra Ortalaması	3,64	10,97	10,91	14,39	6,91	5,30	7,79	9,70	9,61

Tablo 2.11. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde eğitim doğrulukları tablosu (devamı).

Veri Kümesi	ObliqueDT*	OCEC*	OIGA*	PGIRLA*	SIA*	Target*	UCS*	XCS*
Cam1	**100,00% (1)**	70,44% (8)	48,13% (14)	75,47% (6)	**100,00% (1)**	66,75% (10)	65,12% (11)	98,90% (2)
Ecoli0vs1	**100,00% (1)**	90,12% (10)	98,85% (4)	98,86% (3)	**100,00% (1)**	98,11% (7)	31,12% (12)	98,85% (5)
Wisconsin Meme K.	**100,00% (1)**	95,51% (12)	94,92% (13)	91,37% (16)	99,95% (2)	95,98% (11)	98,42% (6)	98,49% (4)
Diyabet	**100,00% (1)**	55,02% (13)	69,36% (9)	71,78% (8)	**100,00% (1)**	57,25% (12)	78,91% (5)	91,05% (2)
Süsen0	**100,00% (1)**	93,44% (4)	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**
Cam0	**100,00% (1)**	77,76% (8)	54,49% (13)	64,10% (12)	**100,00% (1)**	31,29% (15)	33,07% (14)	95,49% (2)
Maya1	**100,00% (1)**	43,79% (11)	50,49% (7)	57,00% (6)	**100,00% (1)**	13,56% (14)	74,58% (3)	45,11% (10)
Taşıtlar1	**100,00% (1)**	70,43% (5)	55,17% (11)	22,19% (14)	**100,00% (1)**	11,04% (15)	78,28% (4)	90,01% (2)
Taşıtlar2	**100,00% (1)**	90,84% (9)	93,00% (8)	18,65% (16)	**100,00% (1)**	49,57% (13)	96,48% (5)	99,71% (2)
Taşıtlar3	**100,00% (1)**	72,15% (5)	51,34% (11)	8,20% (15)	**100,00% (1)**	-	88,53% (3)	90,04% (2)
Haberman	**98,99% (1)**	49,08% (8)	14,85% (17)	55,11% (7)	98,49% (2)	38,57% (13)	55,39% (6)	68,71% (4)
Cam0123vs456	**100,00% (1)**	95,35% (8)	96,57% (6)	94,20% (9)	**100,00% (1)**	91,57% (12)	88,94% (13)	99,11% (2)
Taşıtlar0	**100,00% (1)**	81,12% (9)	94,12% (5)	72,44% (11)	**100,00% (1)**	58,24% (14)	92,96% (6)	99,98% (2)
Ecoli1	**100,00% (1)**	69,87% (12)	92,04% (5)	90,83% (7)	**100,00% (1)**	88,93% (10)	56,94% (15)	94,60% (2)
Yeni Tiroit2	**100,00% (1)**	93,12% (14)	99,86% (2)	98,55% (5)	**100,00% (1)**	95,37% (8)	94,77% (11)	99,57% (3)
Yeni Tiroit1	**100,00% (1)**	88,71% (13)	99,57% (3)	98,78% (6)	**100,00% (1)**	93,78% (9)	92,23% (11)	91,64% (12)
Ecoli2	**100,00% (1)**	61,10% (11)	88,41% (6)	92,79% (4)	**100,00% (1)**	83,35% (8)	64,48% (10)	38,24% (14)
Segmentasyon0	**100,00% (1)**	93,73% (8)	99,08% (5)	-	**100,00% (1)**	82,79% (12)	99,28% (3)	99,47% (2)
Cam6	**100,00% (1)**	97,87% (4)	97,36% (8)	98,70% (3)	**100,00% (1)**	93,40% (12)	97,69% (6)	97,81% (5)
Maya3	**100,00% (1)**	92,34% (5)	87,01% (10)	88,37% (8)	99,77% (2)	53,52% (15)	93,31% (4)	17,25% (16)
Ecoli3	**100,00% (1)**	72,32% (6)	72,29% (8)	72,83% (5)	**100,00% (1)**	-	50,07% (13)	42,53% (14)
Sayfa-Blokları0	99,82% (2)	75,87% (10)	82,82% (9)	74,97% (12)	**99,89% (1)**	58,35% (15)	95,54% (3)	86,25% (7)
Vowel0	**100,00% (1)**	75,16% (11)	93,80% (7)	69,24% (14)	**100,00% (1)**	71,22% (12)	99,56% (3)	97,56% (5)
Cam2	**100,00% (1)**	83,89% (3)	-	-	**100,00% (1)**	-	41,31% (6)	30,69% (8)
Ecoli4	**100,00% (1)**	88,48% (8)	91,30% (6)	92,77% (5)	**100,00% (1)**	71,58% (12)	77,40% (11)	61,05% (13)
Cam4	**100,00% (1)**	96,15% (5)	72,35% (9)	15,27% (14)	**100,00% (1)**	-	74,29% (8)	97,95% (2)
Abalone9vs18	**100,00% (1)**	69,77% (3)	43,58% (10)	23,01% (14)	**100,00% (1)**	10,28% (16)	59,47% (7)	29,97% (13)
Cam5	**100,00% (1)**	95,43% (5)	95,61% (4)	7,07% (14)	**100,00% (1)**	-	63,51% (9)	52,90% (13)
Maya2vs8	**100,00% (1)**	84,79% (4)	38,98% (11)	15,81% (15)	**100,00% (1)**	74,01% (8)	74,33% (7)	73,24% (9)
Maya4	**100,00% (1)**	74,60% (5)	35,67% (9)	19,54% (12)	99,26% (2)	-	82,19% (4)	3,12% (15)
Maya5	**100,00% (1)**	86,08% (5)	69,41% (8)	30,66% (11)	**100,00% (1)**	-	92,97% (3)	-
Maya6	**100,00% (1)**	72,48% (5)	10,00% (10)	-	95,98% (3)	-	82,48% (4)	-
Abalone19	**100,00% (1)**	83,24% (4)	-	-	91,96% (3)	-	49,64% (6)	-
Sıra Ortalaması	1,03	7,61	8,15	9,67	1,24	12,09	7,06	6,88

Tablo 2.12. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde test doğrulukları tablosu.

Veri Kümesi	ABCMiner	COGIN*	CORE*	DMEL*	DT-GA*	Gassist*	GIL*	HIDER*	ILGA*
Cam1	60,11% (9)	43,04% (14)	48,75% (13)	19,76% (17)	65,62% (6)	70,07% (3)	53,14% (11)	64,12% (8)	25,54% (16)
Ecoli0vs1	95,18% (11)	79,53% (15)	95,97% (10)	12,65% (17)	**98,31% (1)**	97,97% (3)	89,20% (13)	96,63% (9)	94,51% (12)
Wisconsin Meme K	96,02% (5)	94,66% (9)	93,77% (12)	53,18% (16)	94,05% (10)	95,23% (8)	96,57% (3)	95,81% (6)	90,51% (15)
Diyabet	67,96% (4)	36,95% (15)	60,13% (11)	16,39% (16)	**69,79% (1)**	65,64% (6)	50,65% (13)	63,23% (7)	61,99% (10)
Süsen0	99,87% (2)	91,16% (8)	**100,00% (1)**	72,46% (11)	98,97% (4)	99,49% (3)	90,65% (9)	**100,00% (1)**	98,48% (5)
Cam0	67,79% (9)	56,51% (12)	63,07% (10)	-	81,02% (3)	81,03% (2)	69,32% (7)	69,63% (6)	56,05% (13)
Maya1	**69,76% (1)**	8,21% (16)	48,64% (7)	-	61,25% (3)	61,23% (4)	40,96% (12)	42,31% (9)	38,58% (13)
Taşıtlar1	**71,58% (1)**	51,36% (10)	34,92% (13)	3,56% (16)	58,28% (7)	56,23% (9)	59,84% (5)	44,69% (11)	32,51% (14)
Taşıtlar2	86,39% (10)	83,97% (12)	36,29% (16)	50,17% (14)	94,23% (4)	94,75% (2)	88,31% (7)	75,16% (13)	86,77% (9)
Taşıtlar3	**72,82% (1)**	50,85% (10)	11,02% (15)	12,96% (14)	57,25% (8)	58,83% (7)	62,87% (5)	43,77% (12)	38,16% (13)
Haberman	**69,46% (1)**	13,90% (15)	37,30% (8)	33,56% (12)	35,63% (11)	45,26% (5)	45,18% (7)	32,31% (13)	9,89% (16)
Cam0123vs456	86,17% (9)	79,87% (15)	80,87% (12)	63,04% (17)	89,24% (4)	88,57% (5)	83,49% (11)	89,90% (2)	77,59% (16)
Taşıtlar0	80,14% (8)	64,90% (12)	12,83% (16)	1,76% (17)	92,58% (2)	90,77% (3)	75,70% (11)	60,81% (13)	79,73% (9)
Ecoli1	86,19% (6)	50,63% (16)	**88,79% (1)**	15,53% (17)	84,91% (8)	86,22% (5)	62,07% (13)	76,56% (11)	87,52% (2)
Yeni Tiroit2	90,33% (11)	81,94% (15)	88,83% (12)	78,13% (16)	92,17% (6)	**97,67% (1)**	93,51% (3)	87,57% (13)	90,67% (9)
Yeni Tiroit1	92,93% (5)	83,96% (13)	91,25% (9)	83,63% (16)	90,86% (10)	**96,21% (1)**	83,77% (14)	92,32% (6)	94,30% (3)
Ecoli2	**89,18% (1)**	37,37% (15)	78,00% (8)	-	77,55% (9)	87,91% (2)	53,17% (13)	59,37% (11)	76,20% (10)
Segmentasyon0	89,52% (11)	65,13% (14)	-	-	98,19% (6)	98,00% (8)	93,31% (10)	80,39% (13)	98,08% (7)
Cam6	91,78% (3)	84,87% (9)	73,70% (16)	50,68% (17)	79,42% (14)	84,74% (10)	88,31% (8)	76,25% (15)	83,30% (12)
Maya3	**92,29% (1)**	54,06% (13)	70,10% (11)	-	82,38% (7)	85,25% (5)	90,36% (3)	52,27% (15)	63,65% (12)
Ecoli3	**86,88% (1)**	56,70% (8)	48,79% (10)	7,30% (16)	72,68% (2)	67,11% (4)	66,32% (5)	45,04% (12)	40,23% (14)
Sayfa-Blokları0	91,60% (2)	55,01% (15)	64,92% (12)	-	**92,18% (1)**	80,87% (9)	74,73% (11)	89,27% (4)	62,49% (13)
Vowel0	95,20% (5)	39,67% (16)	72,60% (11)	16,86% (17)	96,83% (2)	93,60% (6)	62,77% (13)	76,37% (10)	81,71% (9)
Cam2	**85,53% (1)**	-	10,00% (7)	-	52,59% (4)	-	67,11% (2)	-	-
Ecoli4	**94,41% (1)**	27,18% (16)	78,40% (4)	7,56% (17)	82,33% (3)	78,02% (5)	73,38% (8)	69,50% (9)	58,00% (14)
Cam4	88,99% (2)	35,79% (12)	56,47% (8)	7,63% (16)	30,09% (13)	62,51% (7)	66,51% (5)	41,55% (10)	48,49% (9)
Abalone9vs18	**87,66% (1)**	20,56% (12)	32,73% (10)	44,67% (6)	44,78% (5)	40,41% (8)	53,50% (3)	18,55% (14)	7,07% (16)
Cam5	93,29% (2)	19,75% (11)	73,47% (4)	-	42,25% (8)	13,97% (12)	72,01% (5)	32,87% (10)	-
Maya2vs8	**94,60% (1)**	65,46% (9)	72,66% (3)	25,55% (12)	10,00% (13)	62,74% (10)	71,23% (5)	69,58% (7)	-
Maya4	**95,28% (1)**	8,91% (12)	6,31% (13)	-	39,92% (6)	17,16% (8)	58,91% (3)	6,30% (14)	12,31% (10)
Maya5	**95,86% (1)**	26,56% (11)	9,43% (13)	-	83,67% (2)	72,67% (8)	79,44% (4)	-	13,69% (12)
Maya6	**97,64% (1)**	18,20% (8)	-	-	56,60% (4)	-	56,43% (5)	-	-
Abalone19	**99,23% (1)**	-	-	8,04% (4)	-	-	68,96% (2)	-	-
Sıra Ortalaması	3,91	12,21	9,88	14,58	5,85	5,85	7,55	9,76	11,03

Tablo 2.13. Algoritmaların dengesiz sınıf dağılımlı veri kümeleri üzerinde test doğrulukları tablosu (devamı).

Veri Kümesi	ObliqueDT*	OCEC*	OIGA*	PGIRLA*	SIA*	Target*	UCS*	XCS*
Cam1	68,57% (4)	50,79% (12)	37,34% (15)	65,69% (5)	74,51% (2)	64,38% (7)	55,40% (10)	**75,07% (1)**
Ecoli0vs1	96,90% (8)	87,73% (14)	96,99% (6)	97,61% (5)	96,90% (7)	98,28% (2)	20,00% (16)	97,67% (4)
Wisconsin Meme K.	93,21% (13)	95,38% (7)	91,74% (14)	52,93% (17)	96,61% (2)	93,93% (11)	96,22% (4)	**96,97% (1)**
Diyabet	66,94% (5)	50,38% (14)	62,45% (9)	-	63,17% (8)	55,33% (12)	69,14% (2)	68,05% (3)
Süsen0	97,89% (7)	89,83% (10)	97,95% (6)	98,97% (4)	**100,00% (1)**	98,97% (4)	98,97% (4)	**100,00% (1)**
Cam0	74,53% (5)	68,40% (8)	49,17% (14)	59,51% (11)	77,20% (4)	31,19% (15)	30,93% (16)	**83,29% (1)**
Maya1	61,20% (5)	41,15% (11)	47,72% (8)	27,85% (14)	57,08% (6)	14,27% (15)	68,76% (2)	41,59% (10)
Taşıtlar1	66,92% (2)	58,95% (6)	43,77% (12)	-	57,71% (8)	8,42% (15)	62,74% (4)	64,06% (3)
Taşıtlar2	94,48% (3)	88,41% (6)	88,14% (8)	17,23% (17)	85,09% (11)	49,68% (15)	92,63% (5)	**97,06% (1)**
Taşıtlar3	65,21% (3)	65,12% (4)	44,75% (11)	5,30% (16)	53,18% (9)	-	69,14% (2)	59,82% (6)
Haberman	59,77% (2)	45,26% (6)	5,00% (17)	17,59% (14)	52,29% (3)	36,49% (10)	47,87% (4)	36,55% (9)
Cam0123vs456	87,19% (6)	85,35% (10)	79,99% (14)	80,16% (13)	86,97% (8)	89,53% (3)	87,07% (7)	**93,11% (1)**
Taşıtlar0	90,07% (4)	76,49% (10)	89,00% (5)	15,29% (15)	80,54% (7)	58,10% (14)	88,64% (6)	**95,37% (1)**
Ecoli1	81,55% (9)	58,72% (14)	81,44% (10)	85,60% (7)	73,85% (12)	86,64% (4)	58,09% (15)	87,29% (3)
Yeni Tiroit2	93,29% (4)	93,51% (3)	86,43% (14)	92,45% (5)	90,37% (10)	91,66% (7)	91,59% (8)	96,49% (2)
Yeni Tiroit1	95,65% (2)	83,68% (15)	91,35% (8)	37,98% (17)	91,87% (7)	93,77% (4)	89,55% (12)	90,00% (11)
Ecoli2	86,47% (4)	53,49% (12)	79,80% (7)	82,88% (5)	86,90% (3)	82,28% (6)	50,81% (14)	30,82% (16)
Segmentasyon0	98,41% (4)	93,37% (9)	98,26% (5)	-	**99,44% (1)**	80,54% (12)	98,88% (3)	98,98% (2)
Cam6	82,29% (13)	89,15% (6)	83,50% (11)	91,98% (2)	90,63% (4)	89,66% (5)	88,49% (7)	**94,00% (1)**
Maya3	82,05% (8)	90,55% (2)	80,50% (10)	83,67% (6)	81,71% (9)	53,89% (14)	89,46% (4)	17,18% (16)
Ecoli3	67,15% (3)	63,29% (6)	50,84% (9)	42,14% (13)	61,69% (7)	-	46,29% (11)	31,91% (15)
Sayfa-Blokları0	90,07% (3)	75,14% (10)	81,62% (8)	45,75% (16)	86,59% (5)	59,99% (14)	85,04% (6)	84,58% (7)
Vowel0	95,59% (4)	62,38% (14)	84,52% (8)	60,33% (15)	**100,00% (1)**	71,07% (12)	96,68% (3)	90,81% (7)
Cam2	32,05% (5)	65,99% (3)	-	-	19,34% (6)	-	9,61% (8)	-
Ecoli4	88,09% (2)	76,06% (6)	75,28% (7)	63,74% (13)	65,21% (12)	67,70% (11)	68,73% (10)	44,37% (15)
Cam4	62,70% (6)	69,72% (4)	27,67% (14)	11,40% (15)	**95,41% (1)**	-	36,12% (11)	85,97% (3)
Abalone9vs18	54,11% (2)	48,65% (4)	20,36% (13)	21,19% (11)	40,17% (9)	-	41,36% (7)	14,14% (15)
Cam5	**93,65% (1)**	88,34% (3)	67,62% (7)	-	67,79% (6)	-	33,97% (9)	-
Maya2vs8	69,05% (8)	71,45% (4)	-	10,00% (13)	10,00% (13)	72,83% (2)	56,57% (11)	69,65% (6)
Maya4	55,56% (5)	58,31% (4)	12,34% (9)	11,21% (11)	26,21% (7)	-	59,96% (2)	-
Maya5	80,82% (3)	78,04% (6)	41,32% (9)	28,01% (10)	77,71% (7)	-	78,14% (5)	-
Maya6	62,80% (3)	54,24% (6)	-	-	51,47% (7)	-	75,53% (2)	-
Abalone19	7,53% (5)	61,72% (3)	-	-	-	-	-	-
Sıra Ortalaması	4,88	7,64	9,88	11,39	6,33	10,55	7,15	6,88

2.3.3. Değerlendirme

Bu bölümde kural tabanlı sınıflandırma modeli öğrenimi için yeni geliştirilen ABC'ye dayalı iteratif kural keşfi algoritması (ABCMiner) açıklanmıştır. Algoritmanın değerlendirilmesi amacıyla 13 farklı test problemi üzerinde elde ettiği sonuçlar C4.5, LDWPSO, CORE, SIA, PGIRLA ve HIDER algoritmaları ile karşılaştırılmıştır. Elde edilen sonuçlar incelendiğinde ABCMiner 5,66 ortalama kuralla diğer algoritmalara göre oldukça az sayıda kural içeren sınıflandırma modelleri öğrenmiştir. ABCMiner ortalama eğitim doğruluğu için 4. sırada, test doğruluğu için 6. sırada yer almıştır.

Algoritma 33 dengesiz sınıf dağılımlı test problemi üzerinde çalıştırılmıştır. Sonuçlar COGIN, CORE, DMEL, DT-GA, Gassist, GIL, HIDER, ILGA, ObliqueDT, OCEC, OIGA, PGIRLA, SIA, Target, UCS ve XCS algoritmaları ile karşılaştırılmıştır. Algoritmalar problemler için elde edilen ortalama test doğruluğu sonuçları kullanılarak aralarında sıralandığında elde edilen sıra ortalamaları incelendiğinde ABCMiner algoritması 3,91 sıra ortalaması ile algoritmalar arasında birinci sırada yer almıştır. ABCMiner oldukça az sayıda kural içeren basit modeller öğrenmiş ve test için diğer algoritmalara göre yüksek başarı elde etmiştir. Bunun sebebi ABCMiner'ın karşılaştığı her sınıfı karşılayacak yeterli sayıda kural geliştirmesi ve eğitim verilerini olabildiğince genelleştiren sınıflandırma modelleri öğrenmesidir.

3. BÖLÜM

COABCMINER: İŞBİRLİĞİ YAKLAŞIMI İLE ABC TABANLI SINIFLANDIRMA KURALLARININ KEŞFİ ALGORİTMASI

Bu bölümde, kural tabanlı sınıflandırma modellerinin öğrenimi için geliştirilen ABC'ye dayalı bir birleşik kural öğrenme algoritması olan CoABCMiner açıklanmaktadır.

3.1. CoABCMiner Algoritması

CoABCMiner, sınıflandırma modelinin kural kümesini keşfeden ABC tabanlı yeni bir meta-sezgisel öğrenme algoritmasıdır. CoABCMiner algoritmasının sahip olduğu özellikler ve diğer yöntemlere göre üstünlükleri şu şekilde özetlenebilir:

- Denetimli Öğrenme: CoABCMiner, makineli öğrenme yaklaşımlarından denetimli öğrenmeyi kullanır. Denetimli öğrenme yaklaşımı ile önce eldeki eğitim örnekleri giriş ve çıkış değerleri kullanılarak sınıflandırma modeli geliştirilir, daha sonra bu model bilinmeyen veriler üzerinde tahmin amacıyla kullanılır.
- Michigan Gösterimi: CoABCMiner algoritmasının her bir yiyecek kaynağı sadece bir kuralı temsil etmektedir.
- Hibrit Kodlama: Yiyecek kaynağı içindeki ikili ve nominal öznitelikler ikili temsille, tamsayı ve sürekli öznitelikler ise sürekli sayıyla uygun biçimde kodlanarak araştırılır.
- Ödüllü Yarışma ve Çok-Durumlu Araştırma: Bir kural tabanlı sınıflandırma algoritması, veri kümesini indirgeyerek her biri çözüm uzayının farklı bölgelerini kapsayan kuralları çıkartır. Çok-durumlu araştırma özelliğine sahip meta-sezgisel algoritmalar bir kez çalıştırılarak alt çözümlerin tamamını bulabilmektedir. CoABCMiner çok-durumlu araştırma yeteneğine sahiptir. Algoritmada önerilen

ödüllü yarışma adı verilen yarışma ve işbirliği stratejisi ile ABC algoritmasının kazandığı çok-durumlu araştırma yeteneği bütün kuralların bir arada keşfedilmesini sağlar.

Ödüllü yarışma, örnekleri en doğru karşılayan tekil yiyecek kaynakları alt kümesini (çözüm kümesi) araştırma popülasyonundan çıkartır. Her bir yiyecek kaynağı bir kuralı ifade eder. Ödüllü yarışmada, aynı bölgeyi (eğitim örneklerini) sınıflandıran yiyecek kaynakları birbiri arasında bir rekabete girmektedir. Böylece benzer yiyecek kaynakları arasından yüksek sınıflandırma doğruluğuna sahip yani kaliteli yiyecek kaynakları seçilecektir. Ayrıca, farklı kuralların bir arada keşfi için yiyecek kaynaklarının, çözüm uzayına olabildiğince düzgün biçimde dağıtılmış olması ve birbirine aşırı yakınsamasının önüne geçilmesi gerekmektedir.

CoABCMiner, sınıflandırma probleminde kural öğrenilecek her bir sınıf için bir grup arıyı görevlendirir. Her bir grup kendilerine atanmış sınıf için en uygun kuralları keşfetmeye çalışır. Grup içindeki arılar kendi aralarında bilgi paylaşımı yapabildiği gibi farklı gruplardaki arılarla da bilgi alışverişi yapabilmektedir. Eğer arılar sadece kendi grubundaki arılar ile bilgi paylaşımı yapacak olursa, her bir grupta en yüksek kaliteli tek bir yiyecek kaynağına (kurala) yakınsama durumu ortaya çıkacaktır. Ödül kazanan kurallar bir araya getirilerek o çevrimde keşfedilmiş sınıflandırma modeli oluşturulur.

- Son Sadeleştirme İşlemine İhtiyaç Duymaması: CoABCMiner, çok-durumlu araştırma stratejisini kullanarak tek çalıştırmada en uygun kural kümesini keşfetmektedir. Bundan dolayı kuralların keşfedilmesi sürecinin tamamlanmasının ardından kural kümesinin bir arada tekrar ele alınıp gereksiz şart ve kuralların elenmesi işlemine diğer kural öğrenme yaklaşımlarının aksine, CoABCMiner algoritmasında ihtiyaç yoktur.

- Daha Kısa Süre: İteratif kural öğrenme algoritmalarında bir kural keşfetmek için eğitim örneklerini analiz edilir, örnekleri karşılayan en iyi kural bulunur, keşfedilen kural ile doğru sınıflandırılan örnekler çıkartılır ve daha sonra kalan eğitim örnekleri tekrar analiz edilerek yeni kural keşfi adımı tekrarlanır. Bu durum aynı eğitim örnekleri üzerinde tekrar tekrar araştırılma yapılmasına neden olmaktadır. Bu yaklaşım işlem maliyetini artırmakta ve kural keşfini yavaşlatmaktadır. Bir önceki bölümde verilen ABCMiner algoritması bundan dolayı yavaş çalışmaktadır. CoABCMiner algoritması

ise eğitim örneklerinin tamamını bir seferde inceleyip kuralların hepsini daha kısa sürede keşfetmektedir.

- Değişken Uzunluğa Sahip Kuralları Destekleyen Yeni Arama Yaklaşımı: Temel ABC algoritmasında yiyecek kaynakları, sabit uzunluğa sahiptir. Güncelleme adımında rasgele bir parametre seçilir ve bu parametre üzerinde rastgele bir değişiklik yapılarak komşuluğu araştırılır. Sınıflandırma kurallarını ise bu biçimde araştırmak mümkün değildir. Çünkü kural öğrenme yaklaşımında araştırılan her bir kural değişken uzunlukta olmalıdır. Araştırılan kurallar az sayıda öznitelik içermeli ve farklı örnekleri kapsayan genellemeler yapabilmelidir. Dolayısıyla bir sınıflandırma kuralı özniteliklerin hepsini içermek zorunda değildir.

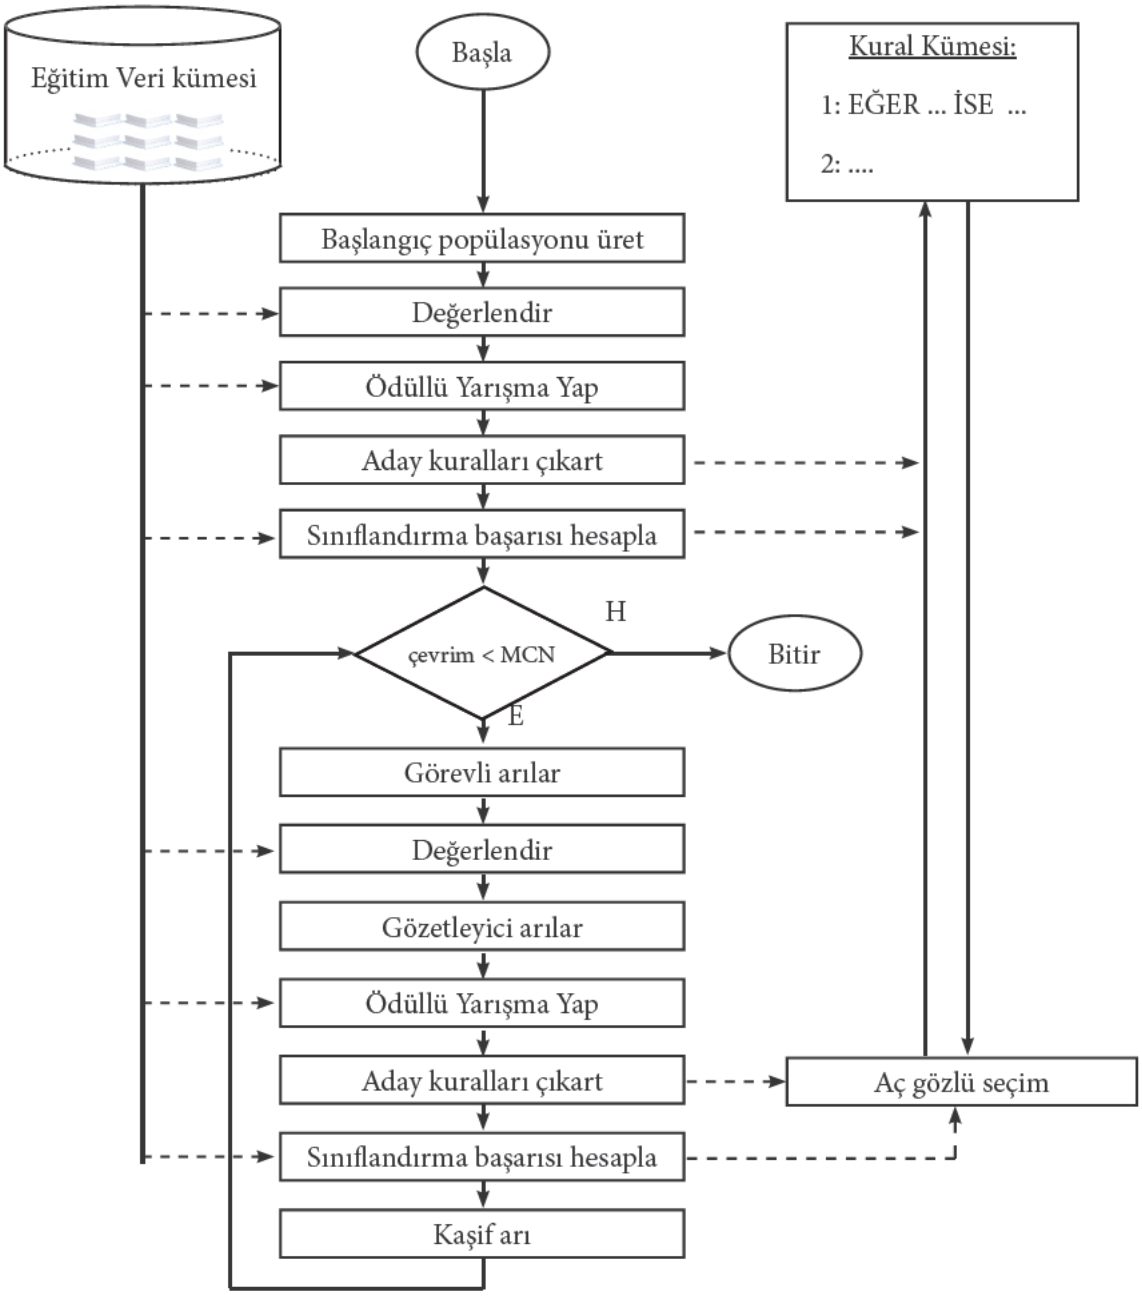
  CoABCMiner algoritmasında değişken uzunluklu çözümler araştırabilmek için temel ABC'dekinden farklı yeni bir yiyecek kaynağı güncelleme stratejisi ortaya konulmuştur. Böylece farklı öznitelik koşullarına sahip değişken uzunluklu yiyecek kaynakları arasında güncellemeler yapılabilmektedir.

- Yeni Kaşif Arı Yaklaşımı: Sınıflandırma kurallarının keşfi probleminde aday çözümler, çözüm uzayı hakkında kısıtlı bilgi veren eğitim örnekleri üzerinde elde edilen performans ile değerlendirilir. Özniteliklerin alabileceği değerlerin kombinasyonu düşünüldüğünde araştırma uzayındaki her farklı durumu ifade edebilmek için oldukça çok sayıda eğitim örneği toplanılması gerekir. Bundan dolayı sınıflandırma problemi için kullanılacak amaç fonksiyonu, daha önce karşılaşılmayan çözüm uzayının bir noktasını değerlendirebilecek yetenekte değildir. Temel ABC algoritmasında kaşif arı rasgele çözümler üretir. Ancak rastgele üretilen bir çözümün kalitesi eğitim örnekleri ile örtüşmediğinde hesaplanamayacaktır. CoABCMiner algoritmasında yeni bir kaşif arı stratejisi tanımlanmıştır. Bu stratejiye göre kaşif arı daha önce karşılanmamış herhangi bir örneği kapsayacak biçimde rasgele yeni bir kural üretir. Böylece çözümlerin birbirine aşırı benzemesinin önüne geçilerek populasyondaki çeşitlilik korunur.

- Amaç Fonksiyonunda Ceza Çarpanı: Kuralların eğitim örnekleri karşısında kalitelerini değerlendirmek için kullanılan amaç fonksiyonuna Yanlış Pozitif (FP) oranını azaltabilmek amacıyla yeni bir ceza çarpanı eklenmiştir. Böylece sınıflandırma

modelindeki kuralların yanlış sınıflandırma (FP) oranı azaltılmaya çalışılmıştır.

CoABCMiner algoritmasının akış diyagramı Şekil 3.1'de ve kaba kodu Algoritma 3.1'de verilmektedir. Algoritmanın girişi önceden toplanmış öznitelik ve sınıf değerlerini içeren eğitim örnekleri çıkışı ise eğitim örneklerini en doğru modelleyen sınıflandırma kuralları kümesidir. Araştırmaya başlamadan önce arama işlemlerinin her öznitelik için standart bir aralıkta yapılabilmesi amacıyla eğitim örneklerinin öznitelik değerleri, $[0, 1]$ arasında normalleştirilir (4. adım). Daha sonra yiyecek kaynaklarına başlangıç değerleri atanır (5. adım). Başlangıç çözümlerinin değerlendirilmesi yapılarak kaliteleri hesaplanır (6. adım). Yiyecek kaynakları arasında ödüllü yarışma yapılır (7. adım). Ödüllü yarışma sonrasında ödül kazanan yiyecek kaynakları kullanılarak aday sınıflandırma modeli çıkartılır (8. adım). Sınıflandırma modelinin eğitim örnekleri üzerinde sınıflandırma başarısı hesaplanır (9. adım). Daha sonra maksimum çevrim sayısı kadar CoABCMiner algoritmasının eğitim işlemleri tekrarlanır (11.-29. adım). Tekrarlanan temel adımlarda öncelikle görevli arılar yiyecek kaynaklarına gönderilerek yeni kurallar elde edilir (12. adım). Görevli arılar araştırması tamamlandıktan sonra yeni ile eski yiyecek kaynakları arasında aç gözlü seçim işlemi gerçekleştirilir (14. adım). Bir sonraki aşamada gözcü arılar yiyecek kaynaklarına gönderilir yiyecek kaynaklarının komşulukları araştırılır ve iyileştirilmeye çalışılır (16. adım). Gözcü arılar araştırmasından sonra eldeki yiyecek kaynakları arasında ödüllü yarışma gerçekleştirilir (17. adım). Ödül kazanan yiyecek kaynakları sınıflandırma kurallarına dönüştürülerek ilgili çevrimin sınıflandırma modeli elde edilir (18. adım). Aday sınıflandırma modelinin eğitim örnekleri üzerindeki sınıflandırma başarısı hesaplanır (19. adım). Aday model ile hafızada tutulan en iyi model arasında sınıflandırma başarısı ve şart sayısı üzerinden yapılan karşılaştırma sonrası gerekirse hafızada tutulan en iyi sınıflandırma modeli güncellenir (20.-23. adım). Görevli arılar arasında kaşif arıya dönüşen olup olmadığı kontrol edilerek (24. adım) şart sağlanıyorsa kaşif arı işlemi gerçekleştirilir (25.-27. adım). Algoritmanın bu adımları toplam çevrim sayısı kadar tekrarlanır. Karşılayan sınıf bulunamamış örnekler arasında yer alan en fazla örneğe sahip sınıf bulunur (30. adım) ve bu temel sınıf olarak elde edilen sınıflandırma modeline eklenir (31. adım). Böylece algoritmanın bulabildiği eğitim örneklerini en doğru sınıflandıran kurallar kümesi elde edilir. Aşamalar hakkında detaylı bilgiler aşağıda verilmiştir.



Şekil 3.1. CoABCMiner algoritması öğrenme süreci akış diyagramı.

3.1.1. CoABCMiner Algoritmasında Kural Temsili

CoABCMiner algoritmasındaki Denklem 3.1'de verilen her bir yiyecek kaynağı, *"EĞER* $koşul_1$ *VE* $koşul_2$ *VE* $\ldots$ *VE* $koşul_k$ *İSE* $SINIF_x$*"* biçimindeki tek bir kuralı temsil eder (Michigan gösterimi). Burada m problemdeki toplam öznitelik sayısı, k ise ($k \leq m$) olmak üzere kuraldaki koşul sayısıdır. Her bir özniteliğin koşulu Denklem

Girişler: *eğitimÖrnekleri* : Eğitim için kullanılacak öznitelik-sınıf değerleri örnekleri.
MCN: Toplam çevrim sayısı.
KS : Kolonideki toplam arı sayısı.
Limit: Görevli arının kaşif arıya dönüşebilmesi için aynı yiyecek kaynağı üzerinde yapacağı toplam araştırma sayısının limit değeri.
initOranı: Başlangıç kuralında niteliğin yer alabilmesi olasılığı.
Çıkış : *KuralSeti*: Algoritmanın keşfettiği, eğitim örneklerini en doğru sınıflandırılan kural kümesi.
Data: *SN*: Araştırılan toplam yiyecek kaynağı sayısı.
B: Araştırma uzayının boyutu.
normEğitim: Değerleri [0, 1] arasında normalleştirilmiş eğitim kümesi.
SayısalNS: Araştırılan problemdeki sayısal öznitelik adedi.
NominalNS: Araştırılan problemdeki nominal öznitelik adedi.
YK, *görevliArılar*, *gözetleyiciArılar*: (SN x B) boyutlu çözüm matrisleri.
normFit, *normFitE*: Yiyecek kaynaklarının eğitim kümesi için sınıflandırma performansları.
YKödül: Doğru sınıflandırma kararları için ödül vektörü.
adayKuralSeti: Yiyecek kaynakları alt kümesi (Aday sınıflandırma kuralları).
KSBaşarısı: Aday kuralların eğitim kümesini sınıflandırma doğruluğu.
temelSınıf: Hiç bir kural karşılanmadığında atanacak temel sınıf değeri.

```
1: SN= KS / 2
2: B= ToplamÖzellikAdedi(NominalNS)+ 2 * SayısalNS
3: KuralSeti= []
4: normEğitim= Normalleştir(eğitimÖrnekleri)
5: YK= BaşlangıçDeğerleriAta(öznitelikler, initOranı, SN, B)
6: normFit= Değerlendir(YK)
7: YKödül= ÖdüllüYarışma(YK)
8: KuralSeti= KurallarıÇıkar(YK, YKödül)
9: KSBaşarısı= SınıflandırmaBaşarısıHesapla(KuralSeti,normEğitim)
10: çevrim= 0
11: while (çevrim < MCN) do
12:     görevliArılar= GörevliArılarAdımı(YK)
13:     normFitE= Değerlendir(görevliArılar)
14:     YK= AçGözlüSeçim(YK, görevliArılar, normFit, normFitE)
15:     normFit= Değerlendir(YK)
16:     YK= GözcüArılarAdımı(YK)
17:     YKödül= ÖdüllüYarışma(YK)
18:     adayKuralSeti= KurallarıÇıkar(YK, YKödül)
19:     adayBaşarısı= SınıflandırmaBaşarısıHesapla(adayKuralSeti, normEğitim)
20:     if ((adayBaşarısı > KSBaşarısı) OR
        ((adayBaşarısı = KSBaşarısı) AND (ŞartSayısı(adayKuralSeti) < ŞartSayısı(KuralSeti)) )) then
21:         KuralSeti= adayKuralSeti
22:         KSBaşarısı= adayBaşarısı
23:     end if
24:     kaşifİndisi= KaşifArıyaDönüşenVarMı(YK, Limit)
25:     if (kaşifİndisi > 0) then
26:         YK[kaşifİndisi,B]= YeniYiyecekKaynağıBelirle()
27:     end if
28:     çevrim= çevrim + 1
29: end while
30: temelSınıf= ArtanÖrneklerdekiMaxSınıfBul(KuralSeti, normEğitim)
31: KuralSeti= TemelSınıfEkle(KuralSeti, default)
return KuralSeti
```

Algoritma 3.1: CoABCMiner algoritması kaba kodu.

3.2'deki koşullardan türüne uygun herhangi biri olabilir. Koşul değerleri bir kuralın ön şartını, sınıf ise ön şart sağlandığında verilecek karar kısmını tanımlar. Her bir yiyecek kaynağının sınıf değeri başlangıç aşamasında belirlenir ve araştırma boyunca sabit tutulur. Tanımlanan özniteliğe uyumlu olacak biçimde yiyecek kaynağında hibrit kodlama kullanılmıştır. Her bir koşul özniteliğinin veri tipine ve kuralda yer alıp almadığına göre ya $SembolikKoşul$ veya $SayısalKoşul$ ya da $BoşKoşul$ ile ifade edilir. Eğer bir öznitelik koşulu $BoşKoşul$ ile ifade edilirse durum testinde özniteliğin aldığı

değer dikkate alınmaz.

$$YiyecekKaynağı_i = \quad koşul_1 \quad VE \quad \ldots \quad VE \quad koşul_m; \quad Sınıf_X \tag{3.1}$$

$$koşul_{ij} = \{BoşKoşul, SembolikKoşul, SayısalKoşul\} \tag{3.2}$$

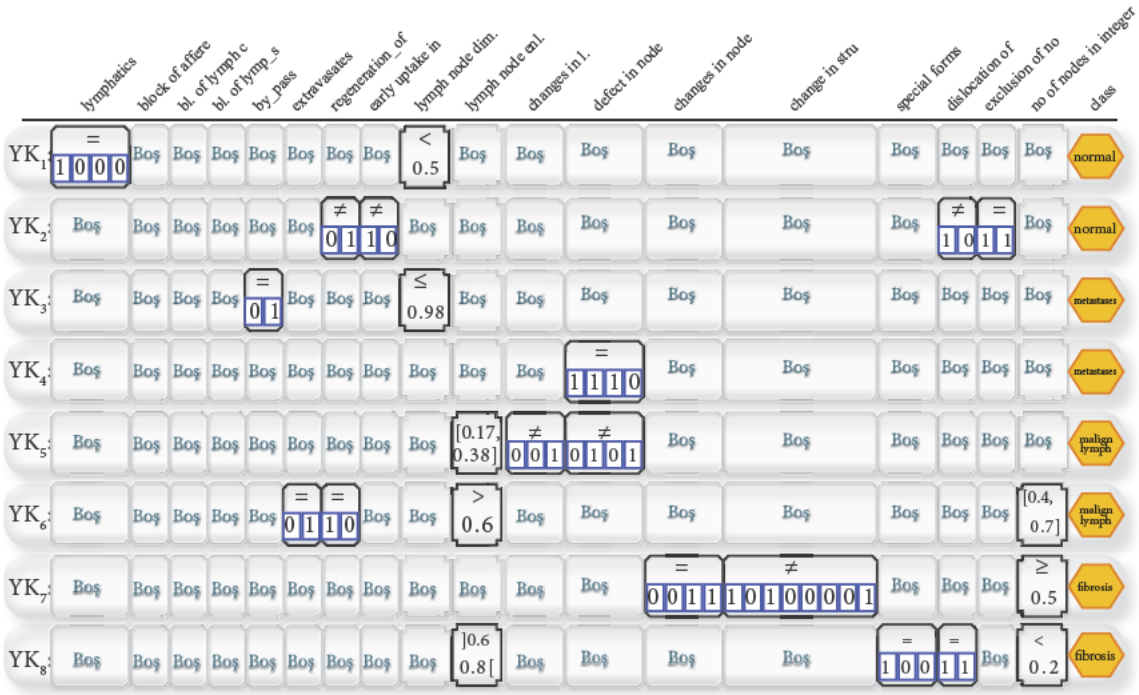
$$SembolikKoşul_{ij} = \{Sembolik\_koşul\_işareti_i; bit_1, \ldots, bit_n\} \tag{3.3}$$

$$SayısalKoşul_{ij} = \{Aralık\_işareti_i; değer_1, değer_2\} \tag{3.4}$$

$$SayısalKoşul_{ij} = \{Karşılaştırma\_işareti_i; değer_1\} \tag{3.5}$$

İkili ve ayrık tipteki özniteliklerin temsili $SembolikKoşul$ kullanılarak yapılır. $SembolikKoşul$ ifade edilen özniteliğin sahip olduğu durum etiketi sayısı kadar bit içeren ikili kod gösterimi ile temsil edilir (Denklem 3.3). Özniteliğin her durumu temsil eden bit değeri 1 olduğunda koşul içinde yer alır. Veride sadece bir durum olacağından sembolik koşuldaki durumlar VEYA bağlacı ile bağlanır. $SembolikKoşul$ öznitelik değerinin karşılaştırılması için $Sembolik\_koşul\_işareti_i$ ***eşittir*** ($=$) veya ***eşit değildir*** ($\neq$) biçiminde iki farklı karşılaştırma işaretine sahip olabilir.

Şekil 3.2'de öznitelik adları üstte ve yiyecek kaynakları (YK_i) adları solda verilmektedir. Her bir yiyecek kaynağının son sutünundaki petek şekli araştırılan kuralın sınıf değerini belirtir. Verilen şekildeki (***changes in node***) özniteliği için *{no, lacunar, lac margin ve lac central}* olmak üzere 4 farklı durum etiketi sözkonusudur. Yedinci yiyecek kaynağının (YK_7) bu öznitelik için sahip olduğu değer ($= 0011$)'dir. Bu, *"Eğer **changes in node** öznitelik değeri 'lac margin' veya 'lac central' etiketine eşit ise"* şeklinde ifade edilir. Eğer bir $SembolikKoşul$'un bit değerlerinin hepsi 1 ya da 0 olursa bu koşul testi dikkate alınmaz ve $BoşKoşul$'a çevrilir.



Şekil 3.2. Lenf grafisi için CoABCMiner'a ait örnek bir başlangıç yiyecek kaynaklarının (kural) gösterimi.

Reel ya da tam sayı türdeki sayısal özniteliklerin temsili $SayısalKoşul$ kullanılarak yapılır. $SayısalKoşul$ Denklem 3.4 ve 3.5 ile verilen biçimlerden herhangi biri olabilir. $SayısalKoşul$, $Aralık\_işareti_i$ olarak değer aralığı içinde ([ ]) ve değer aralığı dışında (] [); $Karşılaştırma\_işareti_i$ olarak büyüktür (>), küçüktür (<), büyük eşittir ($\geq$), ve küçük eşittir ($\leq$) olmak üzere 6 farklı karşılaştırma işaretinden herhangi birine sahip olabilir. $Aralık\_işareti_i$ için iki sayısal değer ve $Karşılaştırma\_işareti_i$ için de tek sayısal değer gerekir. Sayısal koşullar $[0, 1]$ aralığında sürekli değer alabilir. Öznitelik karşılaştırmasının kuraldaki gerçek değerini bulabilmek için $SayısalKoşul$'un sayısal değeri özniteliğin gerçek değerine dönüştürülmelidir.

Şekil 3.2'de verilen gösterimde, (***no of nodes***) sayısal özniteliği $[1, 8]$ arası tam sayı değer alabilmektedir. Yedinci yiyecek kaynağının (YK_7) bu öznitelik değeri (≥ 0.5) olduğu için "*Eğer **no of nodes** öznitelik değeri 4'ten büyükse*" şeklinde ifade edilir. Altıncı yiyecek kaynağında (YK_6) verildiği gibi ($[0.4, 0.7]$) iki değer aralığına sahip olan koşul karşılaştırması "*Eğer **no of nodes** öznitelik değeri 3.2 ile 5.6 arasında ise*" şeklinde ifade edilir.

Bir kuralın koşullarının hepsi bir örnek ile örtüştüğünde kuralın sahip olduğu sınıf değeri

karar olarak atanır. Bir örneği sınıflandırma modelindeki kurallardan birden fazlası karşılaması halinde, en yüksek kaliteli kuralın sınıf değeri karar olarak belirlenir.

3.1.2. CoABCMiner Algoritma Kontrol Parametreleri

CoABCMiner algoritmasında dört kontrol parametresi mevcuttur. Üç kontrol parametresi temel ABC algoritmasında yer alan kontrol parametreleridir: MCN algoritmanın çalışacağı toplam çevrim sayısı, KS kolonideki görevli arı ve toplam yiyecek kaynağı sayısı, $Limit$ yiyecek kaynağının terk edilerek kaşif arı görevlendirilmesi için gerekli deneme eşik sayısıdır. Bunlara ek olarak CoABCMiner, $[0, 1]$ arası değer alabilen başlangıç kurallarının karmaşıklığını belirleyen $initOranı$ adında yeni bir parametreye sahiptir. Yiyecek kaynakları farklı sayılarda koşul içerebildiği için. $initOranı$, bir özniteliğin başlangıç yiyecek kaynaklarının belirlenmesi sırasında kural içinde yer alabilme olasılığını temsil eder. $initOranı$ için yüksek değerler seçilmesi başlangıç kurallarının daha fazla sayıda koşul içermesine sebep olur. Bu da algoritmanın bulacağı kuralların daha karmaşık ve özelleşmiş olmasını sağlar.

3.1.3. Başlangıç Yiyecek Kaynaklarının Değerlerinin Belirlenmesi

CoABCMiner algoritmasının başlangıç aşamasında yiyecek kaynaklarının ilk kural değerleri rasgele biçimde belirlenmektedir. Yiyecek kaynakları K sayıda alt gruba ayrılır. Burada K, araştırılan problemin sahip olduğu sınıf sayısıdır. Her bir yiyecek kaynağına öncelikle sınıf değeri atanır ve sonra kuralların ön şart kısmı belirlenir. Her bir öznitelik kural içinde $initOranı$ olasılıkla yer alabilir ve sırası ile her bir öznitelik için $[0, 1]$ arasında rasgele bir değer üretilir. Eğer üretilen sayı $initOranı$ değerinden küçükse ilgili özniteliğin rasgele belirlenecek koşulu yiyecek kaynağına eklenir, küçük değilse $BoşKoşul$ eklenir.

$SembolikKoşul$ yiyecek kaynağına eklenmek üzere belirlendiğinde, ilk önce hangi karşılaştırma işaretine sahip olacağı rasgele seçilir. Sonra her bir durum etiketi için yer alan bit değeri %50 olasılıkla 1 ya da 0 atanır. $SayısalKoşul$ için yine ilk önce karşılaştırma işareti rasgele seçilir ve işaretle ilgili sayısal değeri/değerleri $[0, 1]$ aralığında rasgele belirlenir.

Lenf grafisi sınıflandırma problemi için kolonideki arıların sahip olduğu yiyecek kaynaklarının örnek bir başlangıç durumu Şekil 3.2'de verilmiştir. Bu problemde 4 sınıf değeri, 18 öznitelik (9 ikili, 6 sembolik, 3 tamsayı) vardır. Her bir sınıfın kural araştırması için ikişer yiyecek kaynağı ayrılmıştır. Kolonide toplam 8 yiyecek kaynağı vardır. Şekilde verilen ilk yiyecek kaynağı (FS_1), "*EĞER* ***lymphatics*** *öznitelik değeri 'normal' ve* ***lymph node dim*** $<$ *1.5 İSE* ***karar sınıfı*** *'normal'dir.*" biçiminde ifade edilir.

3.1.4. Yiyecek Kaynaklarının Kalitesinin Hesaplanması

Algoritma 3.1'in, 6., 13. ve 15. adımlarında yiyecek kaynaklarının kaliteleri, eğitim örnekleri yardımıyla Denklem 3.6 kullanılarak hesaplanmaktadır.

$$\begin{aligned} Kalite(kural_i) &= Ceza_i * Duyarlılık_i * Belirlilik_i \\ &= \frac{N}{(N + FP_i)} * \frac{TP_i}{(TP_i + FN_i)} * \frac{TN_i}{(TN_i + FP_i)} \end{aligned} \tag{3.6}$$

Doğru pozitif (*TP*); kural ön şart kısmının olumlu karşıladığı (pozitif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olanların (doğru karar) sayısıdır.

Yanlış pozitif (*FP*); kural ön şart kısmının olumlu karşıladığı (pozitif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olmayanların (yanlış karar) sayısıdır.

Doğru negatif (*TN*); kural ön şart kısmının olumsuz olup karşılamadığı (negatif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olmayanların (doğru karar) sayısıdır.

Yanlış negatif (*FN*); kural ön şart kısmının olumsuz olup karşılamadığı (negatif test sonucu) eğitim örneklerinden kuralla aynı sınıfa sahip olanların (yanlış karar) sayısıdır.

N; eğitim örneklerinin sayısıdır.

İdeal bir kural kendi karar sınıfına sahip örneklerin hepsini karşılamalı (FN değeri sıfır) ve farklı sınıfa sahip örneklerin hiçbirini karşılamamalıdır (FP değeri sıfır). Bu ideal durumda kalite 1 değerine sahiptir. Kalite değeri hesaplanırken kullanılan ceza oranı, sınıflandırma kurallarının farklı bir sınıfa ait örnekleri yanlış sınıflandırmasını azaltmak

amacıyla eklenmiştir [46].

3.1.5. Yiyecek Kaynakları Arasında Ödüllü Yarışma

Algoritma 3.1'in, 7. ve 17. adımlarında verilen ödüllü yarışma, sınıflandırma modelinin çok modlu çözümünün yiyecek kaynaklarının alt kümesi elde edilerek keşfedildiği aşamasıdır. Bunun için öncelikle her bir eğitim örneğinin öznitelik değerleri yiyecek kaynakları tarafından test edilir. Her bir yiyecek kaynağı doğru sınıflandırdığı her örnek için bir ödül kazanır. Aynı örnek birden fazla yiyecek kaynağı tarafından sınıflandırılırsa yiyecek kaynaklarının kaliteleri göz önüne alınır ve ödül kalitesi daha yüksek olan yiyecek kaynağına verilir. Bu adım sonunda kaliteli yiyecek kaynakları sınıflandırdığı her bir örnek için ödül kazanmış olur.

3.1.6. Sınıflandırma Kurallarının Yiyecek Kaynaklarından Çıkartılması

Aday kuralların çıkartılması algoritmanın 8. ve 18. adımlarında gerçekleştirilmektedir. Bir önceki adımda tespit edilen yiyecek kaynakları sınıflandırma kuralına dönüştürülür. Yiyecek kaynağında $[0, 1]$ arasında reel sayı ile verilen $SayısalKoşul$ değerleri özniteliklerin alabileceği alt ve üst değerler kullanılarak gerçek değerlerine dönüştürülür. Sınıflandırma kuralında sembolik öznitelik, bit dizisi biçiminde kodlanan $SembolikKoşul$'daki değeri bir olan bitlere karşılık gelen sembolik etiketlere dönüştürülür.

Kurallar TP ve FP oranlarını içeren kalite ölçütüne göre azalan biçimde sıralanır. Bu kural kümesi aday sınıflandırma modelini oluşturur. Yeni bir örnek sınıflandırılmak istendiğinde bu sınıflandırma modelindeki her bir kural ile sırasıyla karşılaştırılır. Kurallardan birinin koşulları örnek ile örtüşmesi ile karşılaştırma işlemi durdurulur ve test sonucu doğru çıkan kuralın sınıf değeri sistemin sınıflandırma kararı olarak verilir. Eğer karar veren kural örneği yanlış sınıflandırdıysa (FP), sonraki kurallar arasında örnekle örtüşecek ve doğru sınıflandıracak bir kuralın (TP) yer alması anlamsızlaşacak ve dolayısıyla örnek yanlış sınıflandırılmış olacaktır. Bu durum sınıflandırma modelinin doğruluğunu azaltır. Bundan dolayı kural kümesindeki kurallar kendi aralarında hem TP

hem FP oranlarını içeren kalite değeri kullanılarak sıralanır.

3.1.7. Aday Kuralların Sınıflandırma Doğruluk Başarısının Hesaplanması

Çıkartılan kurallardan oluşan aday sınıflandırma modelinin eğitim örnekleri karşısında elde ettiği sınıflandırma doğruluk başarısı algoritmanın 9. ve 19. adımlarında Denklem 3.7 kullanılarak hesaplanır. Sınıflandırma doğruluk başarısı sınıflandırma modeli tarafından sınıfı doğru tahmin edilen örnek sayısının toplam örnek sayısına olan oranı ile hesaplanır.

$$Model\_Başarısı(Model_j) = \frac{Doğru\_Sınıflandırılmış\_Örnek\_Sayısı_j}{N} \tag{3.7}$$

3.1.8. Görevli ve Gözetleyici Arıların Yiyecek Kaynaklarına Gönderilmesi

Algoritmanın 12. adımında görevli arılar yiyecek kaynaklarına gönderilerek komşu çözümler araştırılır. 16. adımda gözetleyici arılar rulet tekerleği yöntemi ile bir yiyecek kaynağı seçerek komşuluk araştırması gerçekleştirir. Görevli ve gözetleyici arılar, yiyecek kaynağının rasgele seçilen bir parametresini değiştirir. Bu aşamada başka bir yiyecek kaynağının parametre değerinden yararlanılır [81]. CoABCMiner algoritmasında araştırılan parametrelerin $BoşKoşul$ olasılığından dolayı, temel ABC algoritmasındaki güncelleme işlemlerini geliştiren aşağıda detayları verilecek yeni bir yiyecek kaynağı güncelleme stratejisi geliştirilmiş ve CoABCMiner algoritmasında kullanılmıştır.

Her bir koşul testi yiyecek kaynağında *var* ya da *yok* olmak üzere iki farklı durum ile ifade edilir. Seçilen parametrenin bilgi alışverişi yapılacak olan her iki yiyecek kaynağındaki varlık yokluk durumuna göre yapılması gereken güncelleme davranışı farklı biçimlerde gerçekleşir. Bu yaklaşımlar Tablo 3.1'de özetlenmiştir.

i. Koşul Var - Koşul Var: Eğer her iki yiyecek kaynağında da ilgili öznitelik koşulu yer alırsa temel ABC algoritmasında olduğu gibi güncelleme gerçekleştirilir [81].

ii. Koşul Var - Koşul Yok: Eğer araştıran arının yiyecek kaynağında koşul var ve komşu yiyecek kaynağında yok ise koşul $BoşKoşul$'a çevrilir.

Tablo 3.1. CoABCMiner algoritmasının yeni komşu yiyecek kaynağı belirleme stratejisi.

Yiyecek Kaynağındaki Niteliğin Varlık/Yokluk Durumu		Değişim Yaklaşımı	
Kendi	Komşu	(Görevli ve Gözetleyici Arılar Aşamaları)	
Var	Var	İki parametre yardımıyla değeri değiştir	(temel ABC)
Var	Yok	Araştıran arıdaki ilgili koşulu $BoşKoşul$'a çevir	(yeni)
Yok	Var	Komşu yiyecek kaynağındaki koşul değerini kendine kopyala	(yeni)
Yok	Yok	Rasgele yeni bir koşul üret	(yeni)

i. Koşul Yok - Koşul Var: Eğer araştıran arının yiyecek kaynağında koşul yok diğer yiyecek kaynağında var ise diğer yiyecek kaynağındaki koşul değeri kopyalanır.

ii. Koşul Yok - Koşul Yok: Her iki yiyecek kaynağında da koşul olmaması durumunda yeni yiyecek kaynağının ilgili özniteliği için rasgele bir koşul değeri üretilir.

Yiyecek kaynağı %50 olasılıkla koşulun karşılaştırma işaretini komşusundaki işarete çevirebilir ve $SembolikKoşul$'daki her bir bit değeri %50 olasılıkla komşu yiyecek kaynağının sahip olduğu bit değeri ile güncellenir.

Her iki yiyecek kaynağındaki $SayısalKoşul$ farklı işaretlere sahip olması durumunda rasgele seçilen işaret güncellenen koşul testinde kullanılır. Seçilen işarete bağlı olarak bir ya da iki sayısal değerin belirlenmesi gerekir. Her iki yiyecek kaynağında farklı sayıda karşılaştırma değeri olduğunda ise şu şekilde yapılır. Seçilen karşılaştırma işareti tek değer isteyen bir işaret olduğunda ($<, \leq, >, \geq$), koşuldaki değer aralığından ($[değer1, değer2]$) rasgele bir sayı belirlenir ve her iki yiyecek kaynağı arasında temel ABC algoritmasında olduğu gibi işlem yapılır. Seçilen karşılaştırma işareti çift değer isteyen bir işaret olduğunda ($[],][$), tek değere sahip yiyecek kaynağında ya $[0, değer]$ ya da $[değer, 1]$ aralıklarından biri rasgele belirlenir. Aralığın her iki değeri için temel ABC algoritması işlemi yapılır.

3.1.9. En İyi Sınıflandırma Modelinin Hafızaya Alınması

Algoritmanın 20. ile 23. adımları arasında tanımlanan işlemlerle aday sınıflandırma modeli ile hafızada tutulan en iyi model arasında sınıflandırma başarısı ve şart sayısı üzerinden yapılan karşılaştırma sonrası hafızada tutulan model güncellenmektedir. Bu aşamada ilk önce sınıflandırma başarısına dayalı her iki model arasında bir aç gözlü seçim yapılır. Sınıflandırma başarıları eşit olduğunda şart sayıları karşılaştırılıp daha az şarta

sahip olan kural kümesi tercih edilir. Böylece algoritma daha basit ve doğru sınıflandırma başarısına sahip kural kümesini (*KuralSeti*) hafızasında tutar.

3.1.10. Tükenen Kaynağın Terk Edilmesi ve Kaşif Arı Gönderilmesi

Algoritmanın 24. ile 27. adımları arasında deneme sayılı $Limit$ değerini aşan herhangi bir görevli arı olup olmadığı kontrol edilerek gerekirse kaşif arı farklı bir yiyecek kaynağı bulmak üzere gönderilir. Temel ABC algoritması kaşif arı işleminde rastgele bir yiyecek kaynağı belirler. Ancak daha önce Bölüm 3.1'de açıklanan problemlerden dolayı CoABCMiner algoritmasında yeni bir kaşif arı yaklaşımı tanımlanmıştır. Yeni kaşif arı öncelikle eğitim örnekleri arasından daha önce karşılanmamış bir örneği rasgele seçer ve seçilen bu örnek kullanılarak rasgele bir yiyecek kaynağı üretilir. Her bir nitelik yine $initOranı$ ile tanımlı olasılıkla yiyecek kaynağı içinde yer alabilir. Bir öznitelik yiyecek kaynağına eklenmek üzere seçildiğinde koşulun sahip olacağı işaret ve karşılaştırma değerleri veri tipine bağlı olarak rasgele belirlenir. $SembolikKoşul$ ise, örnekteki durum etiketini karşılayan bit değeri (=) işareti için 1, ($\neq$) işareti için 0 yapılır ve diğer bit değerleri rasgele belirlenir. $SayısalKoşul$ ise, ([ ]) or (][) işaretlerinden biri seçildiğinde örnekteki değeri kapsayacak biçimde bir aralık Denklem 3.8 ile belirlenir. Karşılaştırma işareti ($>$) veya ($\geq$) seçildiğinde Denklem 3.9 ile verilen aralık arasında rastgele bir değer, karşılaştırma işareti ($<$) veya ($\leq$) seçildiğinde ise Denklem 3.10 ile verilen aralık arasında rastgele bir değer üretilir.

$$[max\{0, 0.95*normalleştirilmiş(Değer_j)\}, min\{1, 1.05*normalletirilmi(Değer_j)\}] \tag{3.8}$$

$$[max\{0, 0.8 * normalleştirilmiş(Değer_j)\}, normalleştirilmiş(Değer_j)] \tag{3.9}$$

$$[normalleştirilmiş(Değer_j), min\{1, 1.2 * normalleştirilmiş(Değer_j)\},] \tag{3.10}$$

3.1.11. CoABCMiner Algoritmasının Keşfettiği Sınıflandırma Modeli: KuralSeti

Algoritmanın MCN ile belirtilen çevrim sayısı kadar çalıştırılması sonucunda algoritma tarafından öğrenilmiş en yüksek başarı performansına sahip en basit kural kümesi ($KuralSeti$) hafızada tutulur. Hafızadaki kural kümesi ile karşılanamamış eğitim örneklerinde en fazla yer alan sınıf değeri belirlenir. Belirlenen sınıf sınıflandırma yapılırken hiç bir kural tarafından karşılanamayan örnekler için sınıf kararı vermek amacıyla temel sınıf olarak kural kümesine eklenir. Temel sınıf eklenerek elde edilen $KuralSeti$ algoritmanın keşfettiği sınıflandırma modeli olarak kabul edilir.

3.2. Deneyler

Bu bölümde CoABCMiner algoritmasının performansını değerlendirmek üzere iki farklı deney düzeneği hazırlanmıştır. CoABCMiner algoritmasının problemler üzerinde çalıştırılması ile elde edilen eğitim ve test doğruluk sonuçları farklı algoritmalar ile karşılaştırılmıştır. Deneylerde kullanılan algoritmaya ait parametre değerleri Tablo 3.2'de verilmiştir. Diğer algoritmalara ait kontrol parametre değerleri bir önceki bölümde verildiği gibi kullanılmıştır.

3.2.1. CoABCMiner Algoritmasının Sınıflandırma Test Problemleri Üzerindeki Doğruluk Analizi

CoABCMiner ve literatürde yaygın olarak kullanıldığı için seçilen 7 algoritma EK-1'de detayları verilen 13 farklı test problemi üzerinde 5 farklı rastgele üretilmiş başlangıç popülasyonu ile 10 kat çapraz doğrulama yöntemi kullanılarak çalıştırılmıştır. Meta-sezgisel algoritmalar eğitime rastgele başlangıç popülasyonu ile başladığından elde edeceği sınıflandırma modeli küçük hata oranları içerebilir. Algoritmaları daha objektif biçimde karşılaştırmak ve sonuçlardaki muhtemel hataları giderebilmek

Tablo 3.2. CoABCMiner kontrol parametrelerinin deneylerde kullanılan değerleri.

Kontrol Parametresi	Değeri
Toplam Arı Sayısı (KS)	110
Limit	100
Toplam Çevrim Sayısı (MCN)	1000
InitOranı	0,1

için meta-sezgisel algoritma deneyleri 5 farklı başlangıç popülasyonu kullanılarak tekrarlanmıştır. C4.5 algoritması klasik bir sezgisel algoritmadır ve rastgelelik içeren geçiş kuralları kullanmadığından aynı eğitim örnekleri için her zaman aynı sonucu bulabilmektedir. Dolayısıyla C4.5 için bir kez 10 kat çapraz doğrulama yeterli olmaktadır. Yani 5 kez çalıştırmaya gerek olmamıştır.

10 kat çapraz doğrulama yöntemi eğitim için seçilen örneklerden kaynaklanacak hatalı değerlendirmenin önüne geçer. 10 kat çapraz doğrulama işlemine başlamadan önce veri kümesi rastgele 10 ayrı gruba parçalanır ve algoritma ile veriler 10 kez eğitim işlemine tabi tutulur. Her adımda bir parça test için ayrılırken kalan örnekler model eğitiminde kullanılır. Eğitim tamamlandıktan sonra ayrılan test verileri ile öğrenilen modelin sınıflandırma başarısı ölçülür.

Test problemleri üzerinde doğruluk analizi için (7 meta-sezgisel algoritma) x (13 problem) x (5 farklı rastgele başlangıç) x (10 kat çapraz doğrulama) ve C4.5 algoritması için (1 algoritma) x (13 problem) x (10 kat çapraz doğrulama) olmak üzere toplam 4680 deney gerçekleştirilmiştir. CoABCMiner algoritması Java programlama dili kullanılarak kodlanmış ve deneyler Intel(R) Core(TM) i7 3.5 Ghz işlemci ve 16 Gb belleğe sahip kişisel bilgisayarda gerçekleştirilmiştir.

Tablo 3.3'te algoritmaların her birinin elde ettiği eğitim doğruluklarının ortalamaları verilmiştir. Parantez içindeki sayılar algoritmanın problem için başarı sırasını ifade etmektedir. Tablonun alt satırında ise her bir algoritmaya ait ortalama başarı değeri verilmiştir. Tablodan görüldüğü üzere CoABCMiner; %91,99 ortalama ile algoritmalar arasında %96,67 ortalamaya sahip SIA algoritmasından sonra 2. sıradadır. CoABCMiner, hayvanat bahçesi veri kümesini %100 doğruluk ile öğrenmiş, süsen çiçeği haricinde yapılan deneylerde ön sıralarda yer almıştır. SIA algoritması monkun problemi 2 veri kümesi dışında kalan her problemi tam başarı (%100) ile öğrenmiş aşırı öğrenme davranışı sergilemiştir. HIDER algoritması da %90,26 ortalama başarı derecesiyle üçüncü sırada yer almıştır.

Tablo 3.4'te eğitim doğruluklarının standart sapmaları verilmiştir. CoABCMiner %0,67'lik standart sapma ile %0,48 standart sapmaya sahip SIA algoritmasından sonra ikinci sırada yer almıştır. Eğitim doğrulukları incelendiğinde SIA algoritmasının

Tablo 3.3. Ortalama eğitim doğrulukları tablosu.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	%96,75 (2)	%93,18 (4)	%81,51 (6)	%84,22 (5)	%51,00 (8)	**%100 (1)**	%54,48 (7)	%95,64 (3)
Taşıtlar	%69,35 (5)	%71,26 (3)	%69,46 (4)	%65,41 (6)	%59,03 (7)	**%100 (1)**	%56,20 (8)	%82,99 (2)
Soya Fasülyesi	%92,58 (2)	%81,89 (4)	%65,53 (6)	%66,03 (5)	%21,05 (8)	**%98,47 (1)**	%52,91 (7)	%91,03 (3)
Hayvanat Bahçesi	**%100 (1,5)**	%98,57 (4)	%94,18 (7)	%94,80 (6)	%99,78 (3)	**%100 (1,5)**	%93,81 (8)	%96,04 (5)
Mantar	%99,86 (2)	%99,82 (3)	%94,06 (8)	%94,12 (7)	%98,93 (4)	**%99,97 (1)**	%97,42 (5)	%95,83 (6)
Monkun problemi 2	%97,22 (5)	**%100 (1)**	%97,23 (3,5)	%92,48 (7)	%97,95 (2)	%62,22 (8)	%97,07 (6)	%97,23 (3,5)
Süsen Çiçeği	%97,05 (8)	%97,39 (5)	%98,01 (4)	%97,27 (7)	%98,05 (3)	**%100 (1)**	%98,26 (2)	%97,31 (6)
Diyabet	%80,00 (3)	%77,63 (7)	%80,43 (2)	%78,41 (5)	%78,83 (4)	**%100 (1)**	%78,02 (6)	%75,27 (8)
Hepatit	%93,09 (4)	%89,47 (8)	%92,06 (5)	%91,15 (7)	%91,21 (6)	**%98,79 (1)**	%98,06 (2)	%94,15 (3)
Meme Kanseri	%81,31 (2)	%74,57 (8)	%77,79 (5)	%77,55 (6)	%80,51 (4)	**%97,36 (1)**	%80,59 (3)	%75,93 (7)
Wisconsin Meme K.	%98,17 (2)	%97,48 (4)	%97,20 (5)	%96,71 (7)	%97,91 (3)	**%99,84 (1)**	%97,11 (6)	%96,46 (8)
Yeni Tiroid	%97,99 (3)	%96,99 (5)	%98,23 (2)	%96,50 (6)	%97,74 (4)	**%100 (1)**	%96,22 (7)	%94,38 (8)
Lenf Grafisi	%92,45 (2)	%89,64 (3)	%84,41 (5)	%83,96 (7)	%89,10 (4)	**%100 (1)**	%84,06 (6)	%81,15 (8)
Ortalama	%91,99 (2)	%89,84 (4)	%86,93 (5)	%86,05 (6)	%81,62 (8)	**%96,67 (1)**	%83,40 (7)	%90,26 (3)

Tablo 3.4. Eğitim doğrulukları standart sapma değerleri.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	%1,17 (3)	%2,95 (5)	%4,03 (7)	%3,77 (6)	%1,31 (4)	**%0,00 (1)**	%12,94 (8)	%0,44 (2)
Taşıtlar	%1,10 (2)	%1,77 (4)	%2,17 (5)	%3,87 (7)	%5,52 (8)	**%0,00 (1)**	%3,87 (6)	%1,30 (3)
Soya Fasülyesi	%1,18 (3)	%4,40 (6)	%4,19 (5)	%6,60 (8)	%5,19 (7)	**%0,73 (1)**	%3,38 (4)	%0,83 (2)
Hayvanat Bahçesi	**%0,00 (1,5)**	%0,53 (3)	%0,83 (5)	%0,97 (6)	%0,54 (4)	%0,00 (1,5)	%2,34 (8)	%1,78 (7)
Mantar	%0,11 (3)	**%0,04 (1)**	%1,36 (6)	%1,07 (5)	%0,42 (4)	%0,05 (2)	%1,57 (7)	%1,84 (8)
Monkun problemi 2	%0,30 (4)	**%0,00 (1)**	%0,28 (2,5)	%8,46 (8)	%1,20 (6)	%3,61 (7)	%1,14 (5)	%0,28 (2,5)
Süsen Çiçeği	%0,64 (7)	%0,54 (5)	%0,32 (2)	%1,10 (8)	%0,49 (3)	**%0,00 (1)**	%0,61 (6)	%0,49 (4)
Diyabet	%0,75 (3)	%2,96 (8)	%1,09 (7)	%1,03 (5)	%0,61 (2)	**%0,00 (1)**	%0,82 (4)	%1,03 (6)
Hepatit	**%0,84 (1)**	%2,60 (8)	%1,58 (5)	%1,92 (6)	%0,97 (2)	%1,09 (4)	%1,09 (3)	%2,11 (7)
Meme Kanseri	%0,80 (3)	%1,22 (5)	%1,54 (7)	%1,47 (6)	**%0,62 (1)**	%0,72 (2)	%0,83 (4)	%1,88 (8)
Wisconsin Meme K.	%0,19 (2)	%0,53 (6)	%0,24 (4)	%0,68 (7)	%0,22 (3)	**%0,11 (1)**	%0,53 (5)	%1,43 (8)
Yeni Tiroid	%0,63 (2)	%1,98 (8)	%0,81 (4)	%1,05 (6)	%0,81 (5)	**%0,00 (1)**	%0,70 (3)	%1,27 (7)
Lenf Grafisi	%1,00 (2)	%3,76 (8)	%2,15 (4)	%3,01 (7)	%1,68 (3)	**%0,00 (1)**	%2,28 (5)	%2,50 (6)
Ortalama	%0,67 (2)	%1,79 (6)	%1,58 (5)	%2,69 (8)	%1,51 (4)	**%0,48 (1)**	%2,47 (7)	%1,32 (3)

verilen eğitim örnekleri üzerinde yüksek başarıya sahip sınıflandırma modelleri keşfettiği görülmektedir. CoABCMiner algoritması standart sapma değerleri göz önüne alındığında 4 veri kümesi için 2., 5 veri kümesi için 3. ve 1 veri kümesi için 4. olurken süsen çiçeği veri kümesi probleminde 7. olmuştur. Dolayısıyla süsen çiçeği haricindeki veri kümelerinde düşük standart sapma değeri ile başarılı olmuştur.

Tablo 3.5'te algoritmalara ait sınıflandırma test doğruluğu ortalamaları verilmiştir. CoABCMiner algoritması %87,08 ortalama ile algoritmalar arasında en yüksek doğruluğu vermiştir. C4.5 algoritması %84,87 ortalama ile ikinci sıradadır. SIA'nın aşırı öğrenme ile elde ettiği sınıflandırma modelleri, test verisi üzerinde %82,51'lik başarı ile üçüncü olmuş ve algoritmalar arasında eğitimde elde ettiği %96,67 ortalama başarısını gösterememiştir. CoABCMiner e.coli gen dizisi, taşıtlar, diyabet ve meme kanseri veri kümelerinde en yüksek test başarısı elde etmiştir. Yine soya fasülyesi, mantar, yeni tiroit ve lenf grafisi problemlerinde SIA, süsen çiçeği probleminde ise C4.5 algoritmasından

Tablo 3.5. Ortalama test doğrulukları tablosu.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	**%84,02 (1)**	%77,26 (2)	%69,62 (4)	%67,15 (5)	%47,10 (6)	%74,46 (3)	%45,20 (7)	%14,83 (8)
Taşıtlar	**%66,93 (1)**	%66,54 (2)	%48,30 (8)	%50,28 (7)	%57,03 (5)	%62,42 (3)	%52,56 (6)	%59,81 (4)
Soya Fasülyesi	%89,98 (2)	%78,34 (4)	%64,45 (6)	%65,30 (5)	%20,67 (8)	**%90,34 (1)**	%51,39 (7)	%85,91 (3)
Hayvanat Bahçesi	%93,82 (3)	%94,00 (2)	%90,89 (6)	%91,05 (5)	%93,44 (4)	**%95,20 (1)**	%88,07 (8)	%90,27 (7)
Mantar	%99,86 (2)	%99,83 (3)	%90,49 (8)	%93,52 (7)	%98,89 (4)	**%99,98 (1)**	%97,39 (5)	%95,72 (6)
Monkun problemi 2	%97,27 (5)	**%100 (1)**	%97,27 (3,5)	%92,09 (7)	%97,66 (2)	%62,51 (8)	%95,69 (6)	%97,27 (3,5)
Süsen Çiçeği	%96,27 (2)	**%96,66 (1)**	%92,78 (7)	%91,86 (8)	%95,32 (4)	%95,32 (5)	%95,19 (6)	%95,98 (3)
Diyabet	**%75,57 (1)**	%71,73 (4)	%65,94 (8)	%69,59 (7)	%74,35 (2)	%71,41 (5)	%73,13 (3)	%70,91 (6)
Hepatit	%82,06 (3)	%83,93 (2)	%76,70 (8)	%76,76 (7)	%81,16 (5)	%78,58 (6)	**%90,36 (1)**	%81,76 (4)
Meme Kanseri	**%75,86 (1)**	%71,43 (7)	%75,12 (3)	%75,27 (2)	%73,62 (5)	%70,04 (8)	%72,31 (6)	%74,69 (4)
Wisconsin Meme K.	%95,34 (6)	%95,28 (8)	**%96,08 (1)**	%95,70 (4)	%95,73 (3)	%96,02 (2)	%95,51 (5)	%95,30 (7)
Yeni Tiroid	%93,51 (2)	%90,32 (6)	%78,94 (8)	%80,42 (7)	%93,42 (3)	**%94,62 (1)**	%90,94 (4)	%90,46 (5)
Lenf Grafisi	%81,60 (2)	%77,93 (4)	%64,82 (8)	%68,78 (7)	%78,82 (3)	**%81,71 (1)**	%75,85 (5)	%73,37 (6)
Ortalama	**%87,08 (1)**	%84,87 (2)	%77,80 (7)	%78,29 (6)	%77,48 (8)	%82,51 (3)	%78,74 (5)	%78,94 (4)

sonra ikinci sırada yer almaktadır. Ek olarak CoABCMiner algoritmasının e.coli gen dizisi ve soya fasülyesi problemlerinde C4.5, ABCMiner, LDWPSO, CORE, PGIRLA ve HIDER algoritmalarına göre oldukça yüksek sonuçlar ürettiği görülmektedir.

Tablo 3.6'da test standart sapma değerleri verilmektedir. CoABCMiner %5,47 ile CORE algoritmasının elde ettiği %5,32lik standart sapma değerinden sonra ikinci sırada yer almıştır. LDWPSO, ABCMiner ve PGIRLA algoritmaları her problemde 50 deney için en yüksek sapma gösteren algoritmalardır. Tablo 3.7'de sınıflandırma modelleri için en yüksek ve en düşük test doğrulukları verilmiştir. En yüksek değerlere bakıldığında CoABCMiner ve birçok algoritma çalıştırmalar içinde %100 doğruluğa ulaşmaktadır. E.coli gen dizisi probleminde HIDER ve PGIRLA algoritmaları %0, taşıtlar probleminde ABCMiner, LDWPSO ve CORE, %29,8; %35,7 ve %37,6 gibi düşük doğruluklar ile başarısız olmaktadır. CoABCMiner algoritmasının en düşük test

Tablo 3.6. Test doğrulukları standart sapma değerleri.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	%10,44 (2)	%12,05 (3)	%15,36 (7)	%18,72 (8)	**%3,03 (1)**	%14,27 (5)	%14,50 (6)	%13,36 (4)
Taşıtlar	**%3,98 (1)**	%5,07 (3)	%8,37 (8)	%7,28 (6)	%7,68 (7)	%5,56 (5)	%5,40 (4)	%4,72 (2)
Soya Fasülyesi	%3,07 (2)	%4,47 (3)	%5,80 (7)	%8,01 (8)	%5,49 (6)	**%2,86 (1)**	%4,99 (5)	%4,55 (4)
Hayvanat Bahçesi	%8,30 (6)	%6,99 (2)	%8,04 (5)	%9,74 (8)	%7,16 (3)	%7,62 (4)	%8,59 (7)	**%6,55 (1)**
Mantar	%0,14 (2)	%0,20 (3)	%11,40 (8)	%3,08 (7)	%0,51 (4)	**%0,05 (1)**	%1,54 (5)	%1,91 (6)
Monkun problemi 2	%2,68 (4)	**%0,00 (1)**	%2,67 (2,5)	%9,22 (8)	%2,75 (5)	%5,81 (6)	%7,35 (7)	%2,67 (2,5)
Süsen Çiçeği	**%3,60 (1)**	%4,71 (5)	%4,82 (6)	%4,51 (4)	%4,90 (7)	%4,31 (3)	%5,40 (8)	%3,82 (2)
Diyabet	%4,59 (6)	**%3,80 (1)**	%5,31 (8)	%5,02 (7)	%4,02 (2)	%4,42 (5)	%4,12 (3)	%4,30 (4)
Hepatit	%11,08 (8)	%10,49 (7)	%9,37 (4)	%9,23 (2)	%9,30 (3)	**%8,66 (1)**	%10,24 (5)	%10,32 (6)
Meme Kanseri	%6,69 (4)	%7,35 (6)	**%4,95 (1)**	%5,08 (2)	%5,89 (3)	%7,36 (7)	%7,15 (5)	%8,00 (8)
Wisconsin Meme K.	%2,27 (4)	%2,02 (3)	**%1,79 (1)**	%2,45 (6)	%1,81 (2)	%2,35 (5)	%3,09 (7)	%4,00 (8)
Yeni Tiroid	%5,21 (3)	%5,80 (4)	%14,24 (8)	%13,13 (7)	%4,81 (2)	**%4,04 (1)**	%7,06 (6)	%6,48 (5)
Lenf Grafisi	%9,10 (2)	%12,07 (5)	%16,91 (8)	%15,82 (7)	%11,78 (3)	%12,03 (4)	%12,10 (6)	**%8,83 (1)**
Ortalama	%5,47 (2)	%5,77 (3)	%8,39 (7)	%8,56 (8)	**%5,32 (1)**	%6,10 (4)	%7,04 (6)	%6,12 (5)

değeri diğer algoritmaların en düşük test sonuçlarına göre genellikle daha yüksek olduğu görülmektedir.

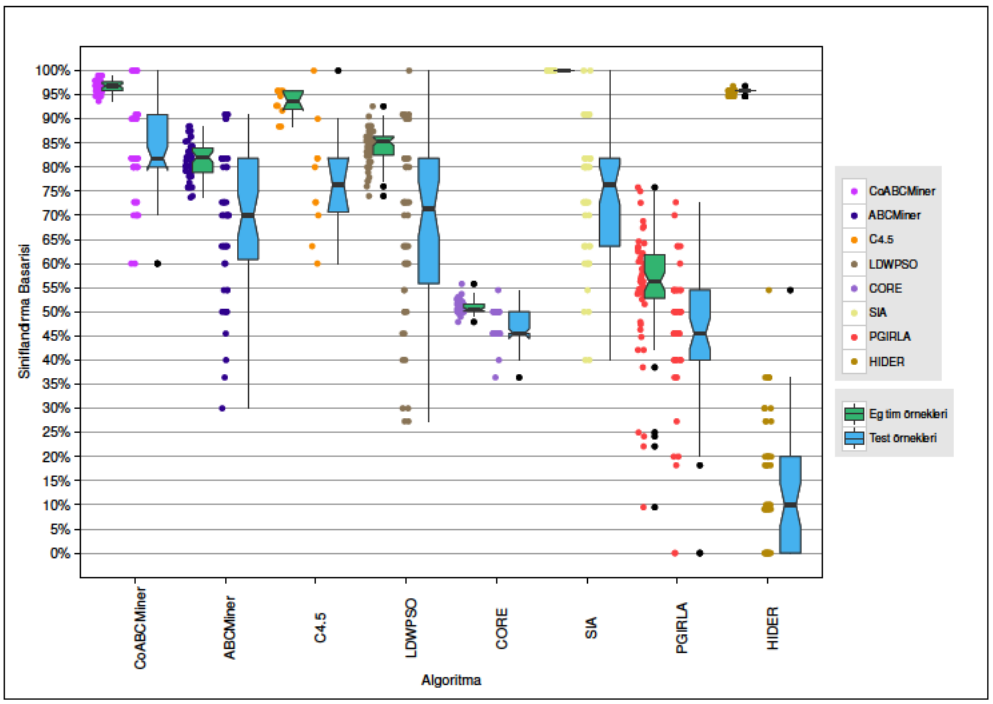
Şekil 3.3, 3.4, 3.5, 3.6, 3.7 ve 3.8'de her bir problem karşısında algoritmaların elde ettiği eğitim ve test doğrulukları için kutu ve saçılım grafiği verilmektedir. Kutu grafiği deney sonuçlarının minimum, orta ve maksimum değerini göstermektedir. Kutu kenarında verilen çizgiler ise elde edilen uç değerleri vermektedir. Kutu grafiği eğitim için yeşil, test için mavi renkle verilmiştir.

Problemler için öğrenilen ortalama kural sayıları Tablo 3.8'de, modellerdeki en az ve en fazla kural sayıları Tablo 3.9'da ve öğrenilen ortalama koşul sayıları Tablo 3.10'da verilmiştir. CoABCMiner algoritması 13,69 kural ortalaması ile 5. sırada, 71,42 koşul sayısı ortalaması ile 6. sırada yer almıştır. CORE algoritmasının en az ve en fazla kural sayıları arasında çok fazla fark olduğu görülmektedir. Bir sınıflandırma modelinin ideal olarak olabildiğince az sayıda kural ve koşul içermesi, ve test başarısının da en yüksek olması arzu edilir. Her iki durumun birlikte iyileştirilemeyeceği şartlarda birinden feragat ederek makul seviyelerde tutulması gerekir. Test başarısının düşük olması ile birlikte modeldeki kural sayısının çok fazla olması algoritmanın aşırı öğrenme davranışı göstermesi ve genelleştirme kabiliyetinin yetersizliğini yani genelleştirilmiş kurallar yerine özelleşmiş kurallar çıkarttığını gösterir. Bu tür kurallar dar bir çözüm bölgesini kapsayacağı için daha önce karşılaşılmamış örneklerin sınıflandırılamamasına veya yanlış sınıflandırılmasına neden olmaktadır.

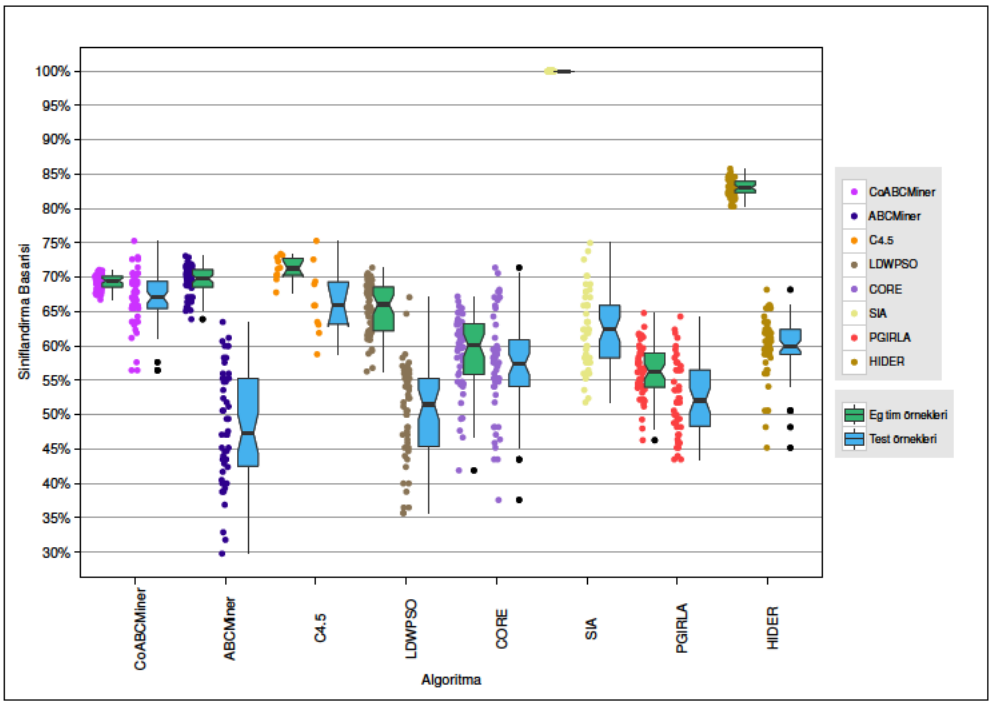
Kural sayısının çok az olması ise modelin çözüm uzayını yeteri hassasiyetle kapsayamaması başka bir deyişle giriş-çıkış uzayları arası bağıntıların öğrenilememesi sonucunu doğurur ve bu da başarıyı düşürür. Modelde basitlik ve sınıf tahmininde yüksek başarının bir arada olamayacağı durumlarda her bir algoritma modelin eğitim başarısı ile basitliği arasında tercih yapmaktadır. Algoritmaların deneylerde öğrendiği kuralların sayıları ve test başarıları ile birlikte değerlendirildiğinde, yüksek test doğruluğu elde etmiş sınıflandırma modellerinin makül seviyelerde kural sayısına sahip oldukları görülmüştür. Tablolara bakıldığında daha başarılı performans sergileyen algoritmaların sınıflandırma modelinde daha fazla kuralın yer aldığı görülmektedir. Bununla birlikte bazen çok kurallı karmaşık modelin öğrenilmesi de yüksek başarıyı sağlamamıştır. SIA, hayvanat bahçesi

Tablo 3.7. En düşük ve en yüksek test doğrulukları tablosu.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E Coli Gen Dizisi	%60,0 - %100	%60,0 - %100	%30,0 - %90,90	%27,30 - %100	%36,40 - %54,50	%40,0 - %100	%0,0 - %72,70	%0,0 - %54,50
Taşıtlar	%56,47 - %75,29	%58,80 - %75,30	%29,80 - %63,50	%35,70 - %67,10	%37,60 - %71,40	%51,80 - %75,0	%43,50 - %64,30	%45,20 - %68,20
Soya Fasülyesi	%84,06 - %95,65	%73,50 - %85,30	%50,0 - %77,90	%45,60 - %80,90	%5,90 - %32,40	%83,80 - %97,10	%37,50 - %59,60	%71,40 - %96,30
Hayvanat Bahçesi	%70,0 - %100	%80,0 - %100	%70,0 - %100	%70,0 - %100	%80,0 - %100	%70,0 - %100	%70,0 - %100	%70,0 - %100
Mantar	%99,38 - %100	%99,30 - %100	%47,50 - %97,0	%76,80 - %97,50	%97,70 - %99,90	%99,80 - %100	%93,80 - %99,50	%89,80 - %98,60
Monkun problemi 2	%90,91 - %100	%100 - %100	%90,90 - %100	%63,20 - %100	%90,90 - %100	%50,0 - %72,70	%55,30 - %100	%90,90 - %100
Süsen Çiçeği	%86,67 - %100	%86,70 - %100	%73,30 - %100	%80,0 - %100	%80,0 - %100	%86,70 - %100	%80,0 - %100	%86,70 - %100
Diyabet	%67,11 - %83,12	%64,90 - %79,20	%53,20 - %76,60	%55,80 - %80,30	%66,20 - %84,20	%62,30 - %83,10	%64,90 - %81,80	%63,60 - %80,50
Hepatit	%60,0 - %100	%62,50 - %100	%56,30 - %100	%46,70 - %93,80	%60,0 - %100	%62,50 - %100	%50,0 - %100	%66,70 - %100
Meme Kanseri	%62,96 - %89,29	%60,70 - %82,10	%66,70 - %82,10	%66,70 - %85,70	%55,60 - %85,70	%50,0 - %82,10	%48,10 - %85,70	%59,30 - %85,70
Wisconsin Meme K	%90,0 - %98,57	%91,40 - %98,60	%92,90 - %100	%89,90 - %100	%91,40 - %98,60	%90,0 - %100	%88,10 - %98,60	%84,10 - %100
Yeni Tiroid	%80,95 - %100	%81,80 - %100	%45,50 - %100	%42,90 - %95,50	%85,70 - %100	%81,0 - %100	%66,70 - %100	%77,30 - %100
Lenf Grafisi	%60,0 - %93,33	%60,0 - %92,90	%21,40 - %93,30	%28,60 - %100	%46,70 - %100	%53,30 - %100	%33,30 - %93,30	%60,0 - %92,90
Ortalama	%74,50 - %95,02	%75,35 - %93,34	%55,96 - %90,87	%56,09 - %92,37	%64,16 - %86,67	%67,78 - %93,08	%56,25 - %88,88	%66,54 - %90,52

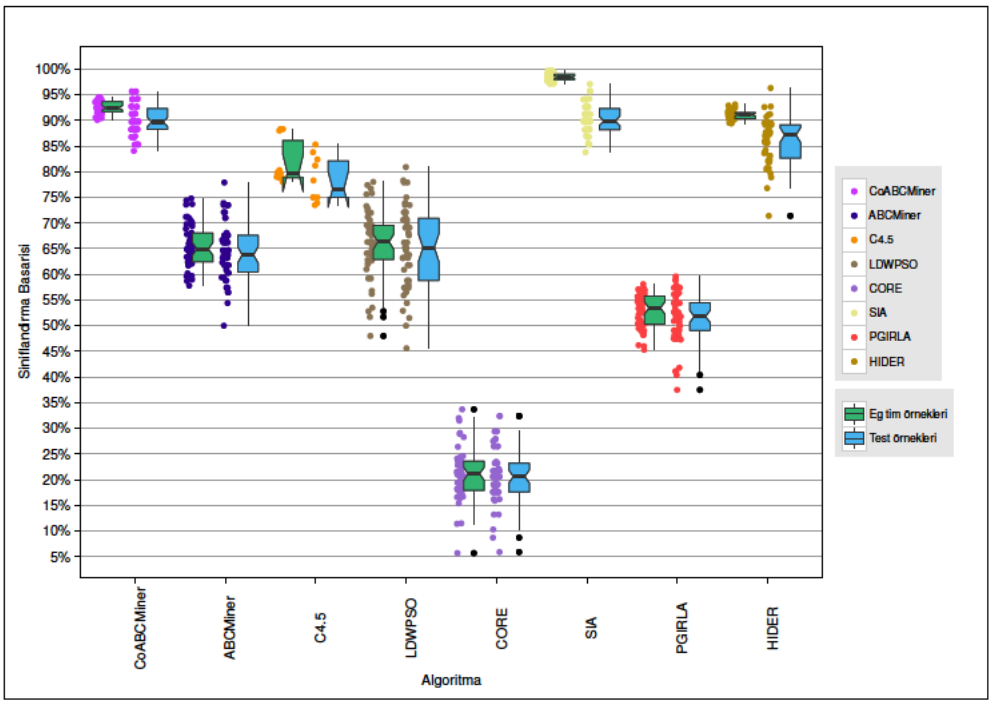


(a) E.coli gen dizisi

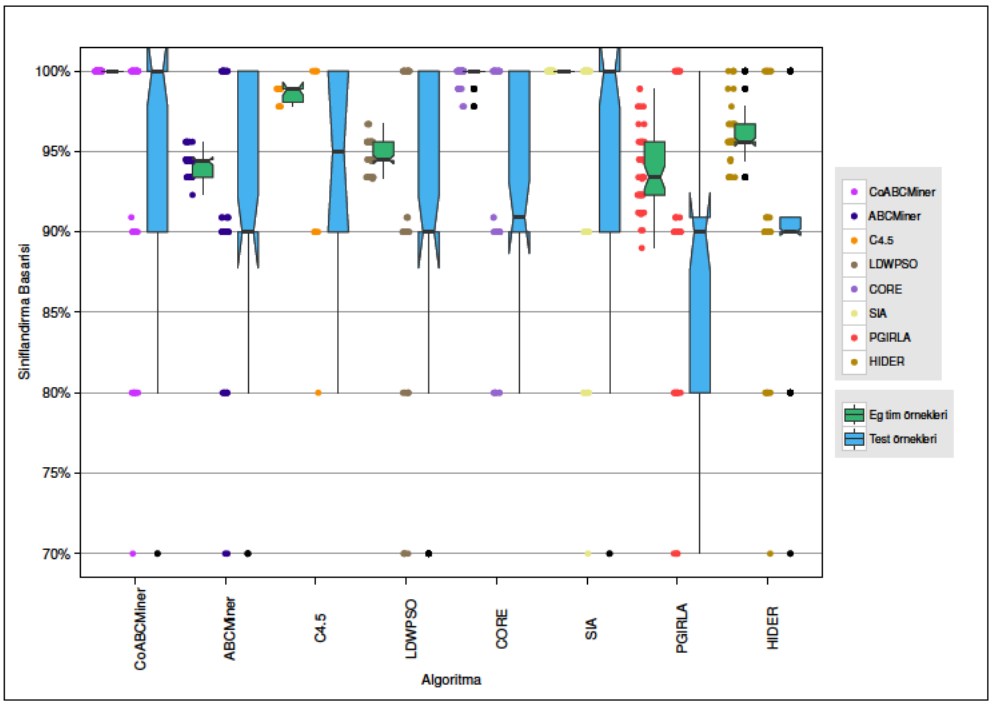


(b) Taşıtlar

Şekil 3.3. E.coli gen dizisi ve taşıtlar veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri.

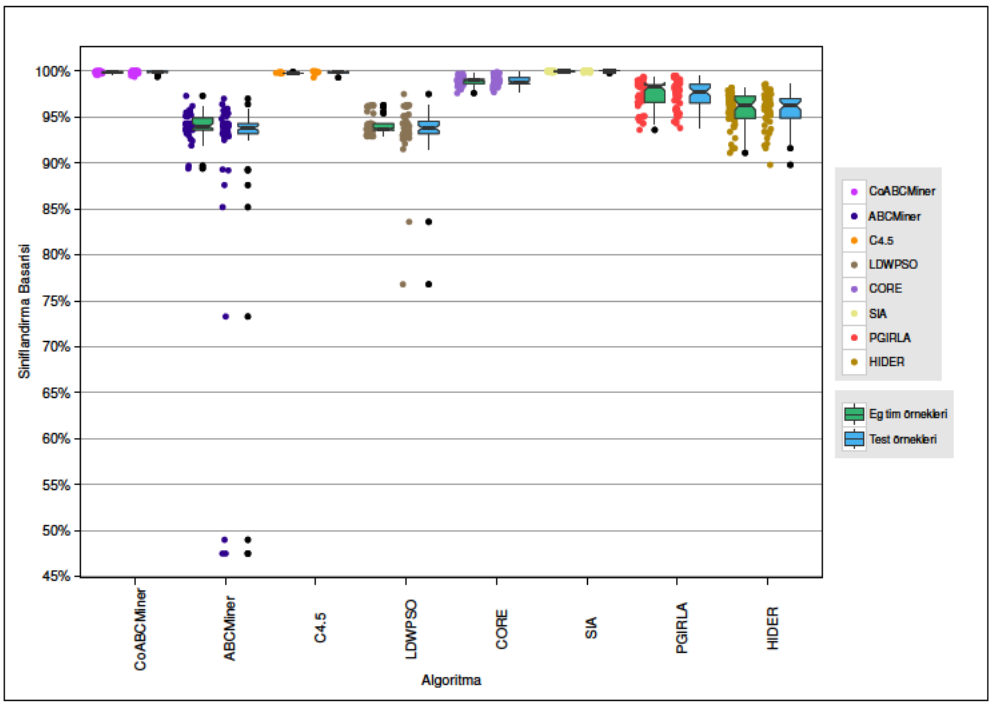


(a) Soya fasülyesi

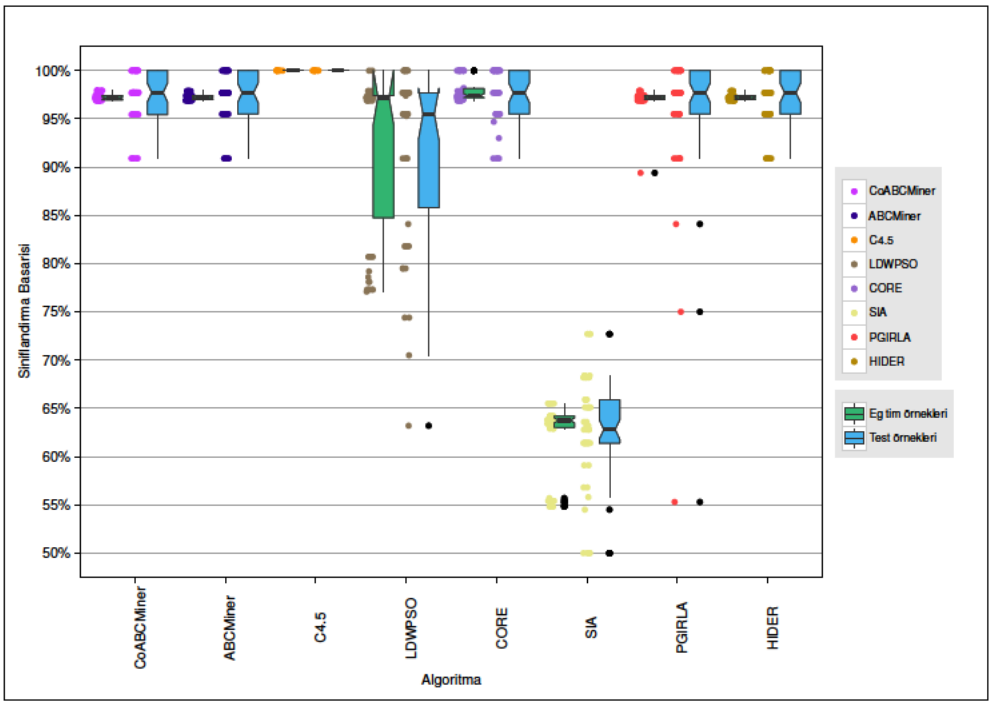


(b) Hayvanat bahçesi

Şekil 3.4. Soya fasülyesi ve hayvanat bahçesi veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri.

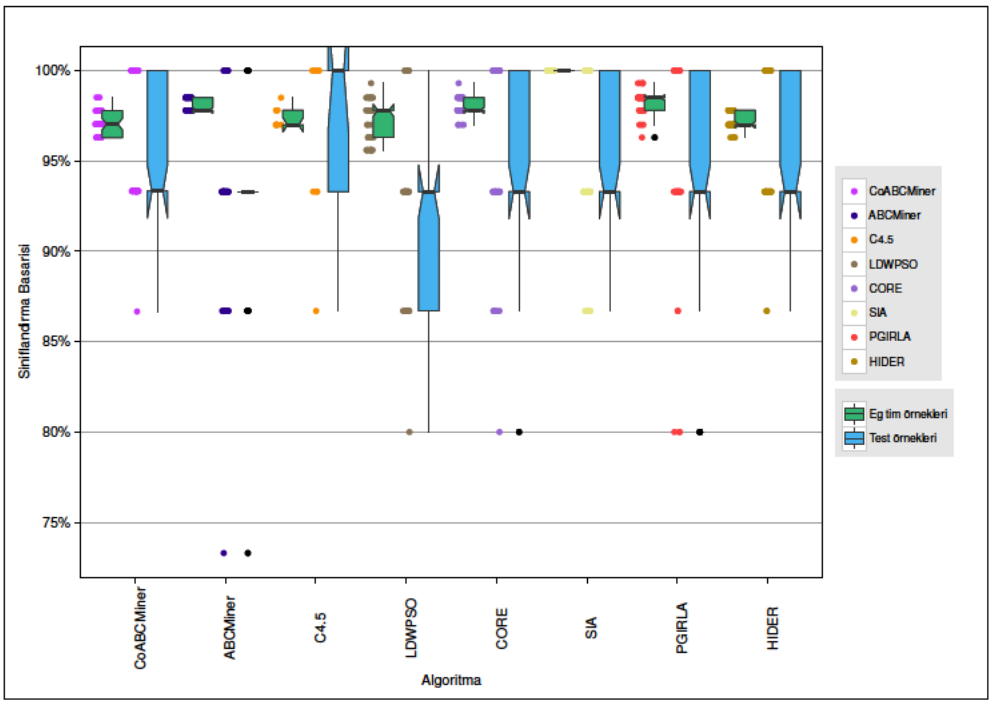


(a) Mantar

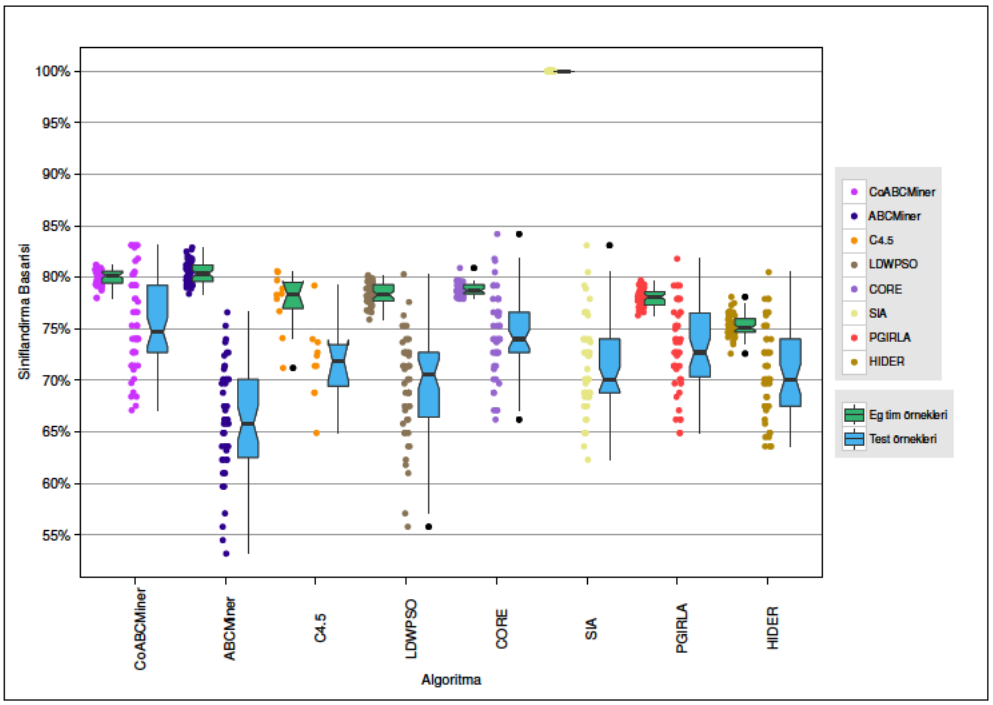


(b) Monkun problemi 2

Şekil 3.5. Mantar ve monkun problemi 2 veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri.

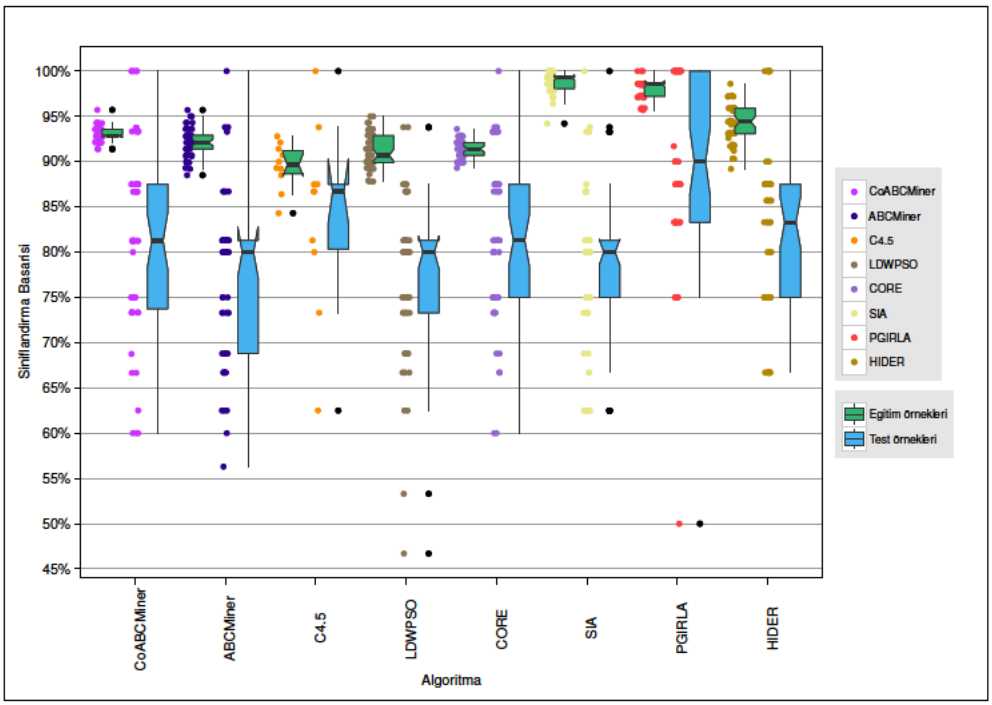


(a) Süsen çiçeği

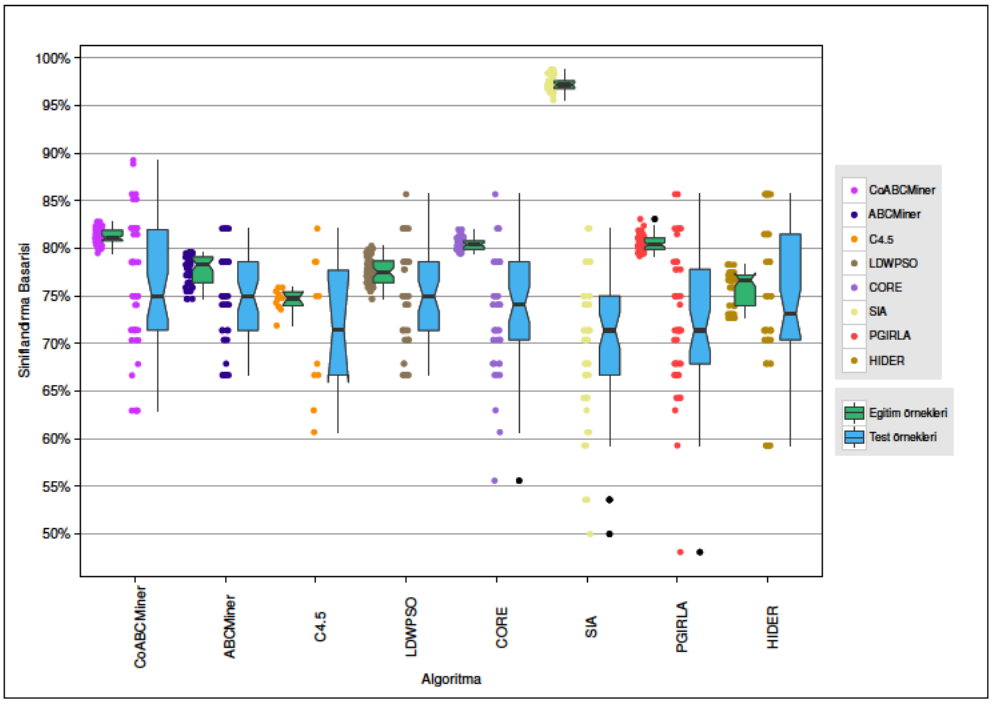


(b) Diyabet

Şekil 3.6. Süsen çiçeği ve diyabet veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri.

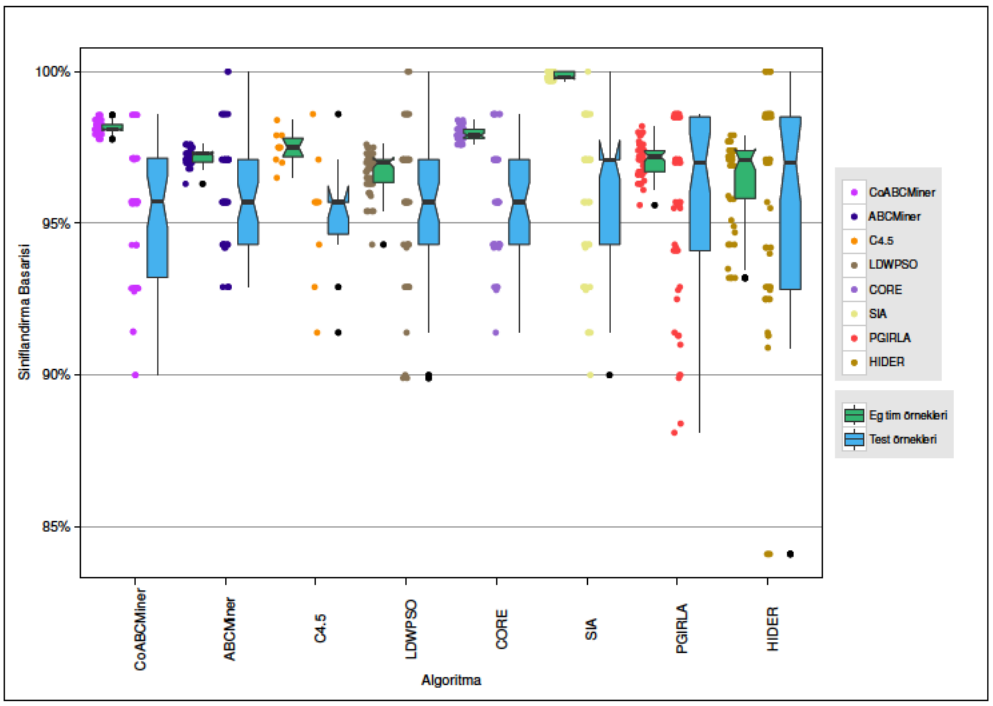


(a) Hepatit

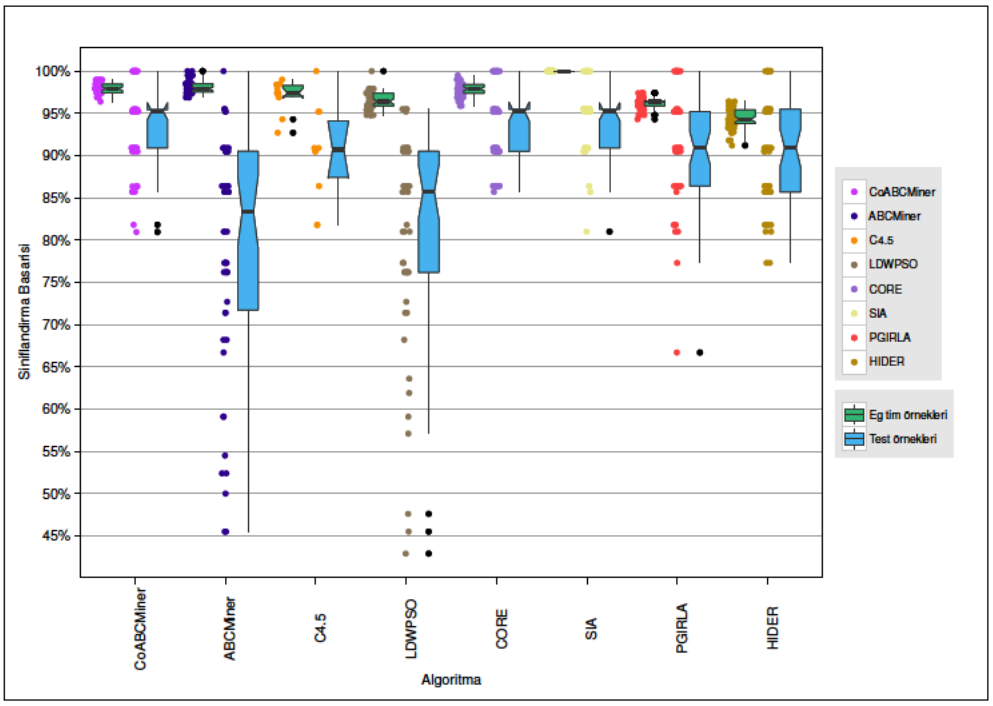


(b) Kanser

Şekil 3.7. Hepatit ve kanser veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri.

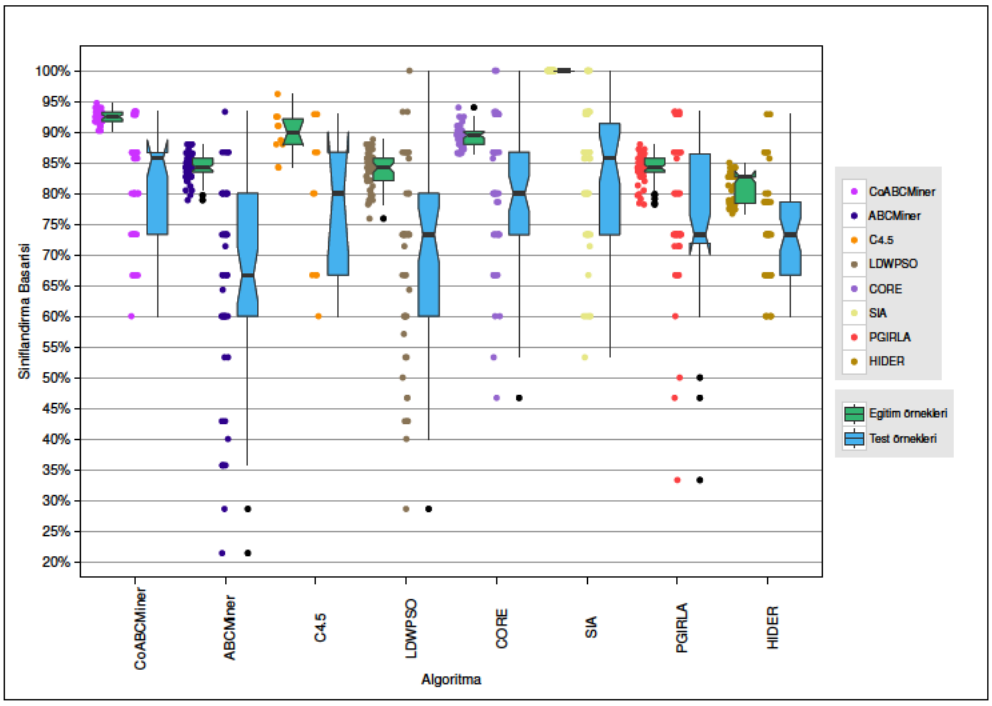


(a) Wisconsin meme kanseri



(b) Yeni tiroid

Şekil 3.8. Wisconsin meme kanseri ve yeni tiroid veri kümeleri için eğitim ve test doğruluklarının kutu ve saçılım grafikleri.



Şekil 3.9. Lenf grafisi için eğitim ve test doğruluklarının kutu ve saçılım grafiği.

Tablo 3.8. Sınıflandırma modellerinin sahip olduğu ortalama kural sayıları.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	HIDER
E.Coli Gen Dizisi	7,8 (4)	9,3 (5)	7,6 (3)	6,5 (2)	**2,5 (1)**	29,1 (6)	71,6 (7)
Taşıtlar	25,7 (5)	18,3 (4)	**8,0 (1)**	8,3 (2)	10,3 (3)	687,2 (7)	46,2 (6)
Soya Fasülyesi	26,3 (5)	39,1 (6)	16,3 (2)	17,1 (3)	**8,7 (1)**	83,9 (7)	20,1 (4)
Hayvanat Bahçesi	7,1 (4)	7,7 (5)	**6,0 (1)**	6,6 (3)	8,1 (6)	9,9 (7)	6,2 (2)
Mantar	7,9 (4)	16,3 (6)	**3,9 (1)**	4,3 (2)	9,4 (5)	24,5 (7)	4,7 (3)
Monkun problemi 2	3,0 (4)	5,0 (6)	**2,0 (1,5)**	2,3 (3)	3,8 (5)	17,7 (7)	**2,0 (1,5)**
Süsen Çiçeği	4,9 (6)	4,0 (4)	**3,0 (1,5)**	3,2 (3)	4,5 (5)	14,4 (7)	**3,0 (1,5)**
Diyabet	30,2 (6)	8,7 (3)	**5,3 (1)**	5,6 (2)	9,2 (4)	599,2 (7)	9,7 (5)
Hepatit	14,1 (6)	6,6 (4)	4,4 (2)	4,6 (3)	7,8 (5)	70,4 (7)	**4,2 (1)**
Meme Kanseri	18,3 (6)	12,5 (5)	5,5 (3)	5,3 (2)	8,2 (4)	88,5 (7)	**2,7 (1)**
Wisconsin Meme K.	12,8 (6)	10,2 (5)	**2,2 (1)**	2,6 (3)	6,8 (4)	40,4 (7)	2,2 (2)
Yeni Tiroid	6,3 (5)	5,6 (4)	4,0 (2,5)	4,0 (2,5)	6,4 (6)	41,8 (7)	**3,3 (1)**
Lenf Grafisi	13,7 (6)	11,3 (5)	5,3 (2)	5,6 (3)	11,0 (4)	32,8 (7)	**3,2 (1)**
Ortalama	13,69 (5)	11,89 (4)	**5,66 (1)**	5,85 (2)	7,44 (3)	133,84 (7)	13,77 (6)

dışındaki problemlerde diğer algoritmalara göre çok fazla kural ve koşul keşfetmiştir. Aşırı öğrenme nedeniyle eğitim aşamasında yüksek başarı göstermesi test başarısını artırmamış ve daha az kurallı modellerin gerisinde bırakmıştır. Tablolarda karşılaşılan başka bir ilginç sonuçda e.coli gen dizisi veri kümesi HIDER algoritmasıyla 71,6 kural ve 1363,62 koşul ile modellenmiştir. Fakat test ortalaması %14,8 ile en son sırada yer almıştır.

Test doğrulukları sıralamasında monkun problemi 2 ve süsen çiçeği problemi için daha başarılı olduğu görülen C4.5 algoritması sırasıyla 5 ve 4 kurallı ve 5 ve 2,7 koşul sayısına

Tablo 3.9. Algoritmalar tarafından öğrenilen en az ve en fazla kural sayıları.

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	HIDER
E.Coli Gen Dizisi	5 - 10	7 - 12	5 - 9	5 - 8	1 - 13	22 - 34	60 - 80
Taşıtlar	21 - 31	16 - 23	7 - 9	8 - 9	5 - 15	655 - 716	41 - 59
Soya Fasülyesi	22 - 33	33 - 45	15 - 17	15 - 18	1 - 15	75 - 95	16 - 25
Hayvanat Bahçesi	7 - 8	7 - 8	6 - 6	6 - 8	7 - 13	8 - 12	6 - 7
Mantar	4 - 11	15 - 18	3 - 5	3 - 6	3 - 14	17 - 36	3 - 7
Monkun problemi 2	3 - 4	5 - 5	2 - 2	2 - 5	2 - 11	16 - 18	2 - 2
Süsen Çiçeği	4 - 6	4 - 4	3 - 3	3 - 5	3 - 13	10 - 20	3 - 3
Diyabet	25 - 37	6 - 13	5 - 6	4 - 7	4 - 14	522 - 648	6 - 12
Hepatit	10 - 18	5 - 8	3 - 6	3 - 6	3 - 14	56 - 91	2 - 7
Meme Kanseri	12 - 23	9 - 18	4 - 6	3 - 6	4 - 14	78 - 97	2 - 3
Wisconsin Meme K.	9 - 16	7 - 15	2 - 4	2 - 4	4 - 13	34 - 48	2 - 3
Yeni Tiroid	4 - 9	5 - 6	4 - 4	4 - 4	3 - 14	26 - 69	3 - 4
Lenf Grafisi	10 - 18	8 - 16	4 - 6	4 - 6	7 - 14	26 - 38	2 - 5
Ortalama	10,5 - 17,2	9,8 - 14,7	4,8 - 6,4	4,8 - 7,1	3,6 - 13,6	118,8 - 147,8	11,4 - 16,7

Tablo 3.10. Sınıflandırma modellerinin sahip olduğu ortalama koşul sayıları.

Veri Kümeleri	CoABC-Miner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E.Coli Gen Dizisi	29,62 (4)	14,1 (3)	6,68 (2)	**5,68 (1)**	37,56 (5)	70,2 (6)	620,4 (7)	1363,62 (8)
Taşıtlar	165,46 (6)	34,5 (2)	34,82 (3)	**29,54 (1)**	44,1 (4)	12189,88 (8)	146,66 (5)	801,96 (7)
Soya Fasülyesi	263,2 (6)	146,6 (4)	**38,74 (1)**	43,78 (2)	89,94 (3)	755,44 (8)	409,3 (7)	176,82 (5)
Hayvanat Bahçesi	28,9 (5)	18,2 (4)	**6,72 (1)**	7,46 (2)	43,1 (6)	49,82 (7)	160,98 (8)	9,46 (3)
Mantar	34,62 (4)	31,7 (3)	**5,5 (1)**	6,18 (2)	46,04 (5)	80,18 (7)	212,62 (8)	73,38 (6)
Monkun problemi 2	3,76 (4)	5,0 (6)	**2,0 (1,5)**	2,04 (3)	4,84 (5)	75,82 (8)	45,82 (7)	2,0 (1,5)
Süsen Çiçeği	8,46 (6)	**2,7 (1)**	3,12 (2)	3,14 (3)	7,4 (5)	45,12 (8)	31,16 (7)	6,64 (4)
Diyabet	123,04 (7)	13,3 (2)	18,38 (3)	**12,24 (1)**	24,3 (4)	4412,78 (8)	63,12 (5)	71,44 (6)
Hepatit	69,92 (6)	11,1 (2)	12,56 (3)	**10,24 (1)**	38,86 (5)	690,0 (8)	197,1 (7)	25,86 (4)
Meme Kanseri	63,68 (6)	40,8 (5)	7,08 (2)	**6,88 (1)**	19,32 (4)	363,04 (8)	77,12 (7)	9,5 (3)
Wisconsin Meme K.	49,84 (6)	8,3 (4)	6,12 (2)	**5,74 (1)**	19,88 (5)	168,78 (8)	66,4 (7)	6,62 (3)
Yeni Tiroid	23,76 (6)	5,8 (2)	6,88 (3)	**5,74 (1)**	15,0 (4)	185,9 (8)	35,84 (7)	15,34 (5)
Lenf Grafisi	64,2 (6)	23,1 (4)	**9,22 (1)**	10,28 (2)	52,36 (5)	140,88 (7)	175,0 (8)	10,82 (3)
Ortalama	71,42 (6)	27,32 (3)	12,14 (2)	**11,46 (1)**	34,05 (5)	1479,06 (8)	172,42 (7)	197,96 (4)

sahip modeller üretirken bir sonraki sırada yer alan CoABCMiner algoritması 3 ve 4,9 kurallı ve 3,76 ve 8,46 koşul sayısına sahip modeller üretmiştir.

ABCMiner ve LDWPSO algoritmaları, en az kural keşfeden 1. ve 2. algoritma olmuştur. Buna rağmen ortaya koydukları basit modeller meme kanseri ve Wisconsin meme kanseri dışındaki problemler üzerinde yeterli başarı elde edememiştir. ABCMiner algoritmalar arasında test başarısı sıralamasında 7. sırada, LDWPSO ise 6. sırada yer almıştır. ABCMiner ortalama 2,2 kurallı model ile Wisconsin meme kanseri probleminde %96,1 test başarısı ile birinci olmuştur. LDWPSO ise meme kanseri probleminde 5,3 kural ve 6,88 koşul ile %75,3 test başarısı ve, CoABCMiner'ın 6 kural ve 63,68 koşul ile %75,9 test başarısının ardından ikinci olmuştur. Kural ve koşul sayıları değerlendirildiğinde CoABCMiner algoritmasının karmaşıklık yönünden dengeli modeller keşfettiği söylenebilir. CoABCMiner ne SIA'da olduğu gibi çok karmaşık, ne de ABCMiner ve LDWPSO'daki gibi çok basit olmayan, ama kabul edilebilir düzeyde kural

ve koşula sahip yani normal karmaşıklıkta sınıflandırma modelleri keşfetmiştir.

Eğitim örneklerinin araştırma uzayına düzgün dağılmaması ve gürültü gibi faktörler sebebiyle eğitimde asıl modelden uzaklaşılmakta ve öğrenilen modelin görülmemiş yeni olaylar karşısındaki tahmin başarısı düşmektedir. Dolayısıyla sonuçlar değerlendirildiğinde yüksek başarılı ve makul basitlikte model keşfeden CoABCMiner algoritmasının başarılı olduğu görülmektedir. Tablo 3.8'de benzer sayılarda kural üreten CoABCMiner, C4.5 ve HIDER algoritmaları ortalama eğitim ve test doğrulukları açısından değerlendirildiğinde de en başarılı algoritmanın CoABCMiner algoritması olduğu görülmektedir.

Tablo 3.11'de algoritmaların ortalama çalışma süreleri milisaniye cinsinden verilmiştir. Klasik sezgisel algoritma olan C4.5 algoritması en hızlı çalışan algoritmadır. Genetik algoritma ve sürü zekasına dayalı meta-sezgisel algoritmalara dayalı diğer yöntemler deneme-yanılma prensibine dayalı olduğu için daha yavaş kalmaktadır. CoABCMiner ortalama çalışma süreleri incelendiğinde algoritmalar arasında 4. sırada yer almıştır. ABCMiner ve LDWPSO algoritmasına göre önemli derecede hızlı olduğu görülmektedir. Bunun sebebi bu algoritmaların her kuralı öğrenmek için ayrı çözüm popülasyonu kullanması, CoABCMiner algoritmasının ise bir çözüm popülasyonu eğitimi sonunda kuralların hepsini keşfetmesidir.

CoABCMiner algoritmasının elde ettiği üstünlüğün istatistiksel bakımdan anlamlı olup olmadığının değerlendirmek amacıyla çeşitli istatistik testler yapılmıştır. Tablo 3.12'de test doğruluğu için orta değere dayalı karşıtlık değerleri verilmektedir. Koyu karakterle gösterilen ifadeler satır başlığında verilen algoritmanın sutunda gösterilen algoritmaya göre üstün olduğunu ifade etmektedir. 13 farklı problem için hesaplanan değerler doğrultusunda CoABCMiner, ABCMiner algoritmasına karşı %6,9 üstünlük ile C4.5 algoritmasına karşı %0,5 üstünlük arasında değişen oranlarda olmak üzere diğer algoritmalardan daha iyi sonuçlar elde etmiştir. Tablo 3.13'te CoABCMiner algoritmasının Friedman ikili analizi z değeri ve çeşitli metotlar ile güncellenmiş p değerleri verilmektedir. Sonuçlara göre CoABCMiner algoritması %5 anlamlılık seviyesinde ABCMiner, LDWPSO, PGIRLA ve HIDER algoritmasına göre istatistiksel açıdan farklı ve daha iyi sonuçlar elde etmiştir. CoABCMiner ile elde edilen test

Tablo 3.11. Algoritmaların kural öğrenmeleri için geçen ortalama çalışma süreleri (msn.).

Veri Kümeleri	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
E Coli Gen Dizisi	24 010 (4)	**300 (1)**	885 144 (7)	2 019 790 (8)	57 280 (5)	2 920 (3)	1 500 (2)	144 600 (6)
Taşıtlar	12 399 (3)	**1 200 (1)**	25 378 (4)	78 357 (6)	171 548 (8)	102 760 (7)	3 200 (2)	61 500 (5)
Soya Fasülyesi	17 091 (3)	**800 (1)**	5 918 583 (7)	10 039 326 (8)	290 785 (6)	19 500 (4)	4 600 (2)	40 700 (5)
Hayvanat Bahçesi	3 174 (4)	**280 (1)**	30 327 (7)	157 195 (8)	29 659 (6)	1 000 (3)	900 (2)	3 500 (5)
Mantar	329 592 (4)	**1 500 (1)**	12 679 894 (7)	18 620 857 (8)	3 742 910 (6)	1 979 920 (5)	20 400 (2)	96 300 (3)
Monkun Problemi 2	4 005 (5)	**100 (1)**	5 167 (6)	7 943 (7)	45 459 (8)	1 000 (2)	1 300 (3)	4 000 (4)
Süsen Çiçeği	2 036 (5)	**200 (1)**	2 906 (6)	7 246 (7)	22 127 (8)	920 (3)	850 (2)	1 500 (4)
Diyabet	7 774 (4)	**600 (1)**	46 283 (5)	66 154 (7)	93 285 (8)	52 960 (6)	2 500 (2)	7 100 (3)
Hepatit	3 671 (5)	**460 (1)**	195 179 (7)	344 093 (8)	30 609 (6)	2 200 (3)	960 (2)	3 200 (4)
Meme Kanseri	4 303 (5)	**400 (1)**	137 526 (7)	202 091 (8)	32 489 (6)	3 620 (4)	1 400 (2)	3 200 (3)
Wisconsin Meme K	9 277 (6)	**500 (1)**	8 845 (5)	16 890 (7)	97 207 (8)	7 040 (4)	2 200 (2)	4 400 (3)
Yeni Tiroid	2 460 (5)	**250 (1)**	4 672 (6)	8 065 (7)	30 433 (8)	1 000 (3)	880 (2)	1 900 (4)
Lenf Grafisi	7 243 (5)	**380 (1)**	227 646 (7)	426 217 (8)	40 298 (6)	1 440 (3)	1 100 (2)	3 600 (4)
Ortalama	32 848 (4)	**536 (1)**	1 551 350 (7)	2 461 094 (8)	360 314 (6)	167 406 (5)	3 214 (2)	28 884 (3)

doğrulukları CORE, C4.5 ve SIA algoritmaları ile istatistiksel açıdan farklı değildir.

Tablo 3.14'te algoritmaların karşılaştırılması için kullanılan parametreler bir arada verilmiştir. Parametrelerin hepsi bir arada değerlendirildiğinde CoABCMiner algoritmasının algoritmalar arasında 1. sırada yer aldığı görülmektedir.

Tablo 3.12. Algoritmaların test doğrulukları için orta değere dayalı karşıtlık değerleri tablosu (contrast estimation based on medians) [133].

	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
CoABC-Miner	**0,005**	**0,069**	**0,066**	**0,022**	**0,012**	**0,033**	**0,03**
C4.5		**0,064**	**0,061**	**0,017**	**0,007**	**0,028**	**0,024**
ABCMiner			-0,003	-0,047	-0,057	-0,036	-0,04
LDWPSO				-0,044	-0,054	-0,033	-0,036
CORE					-0,01	**0,011**	**0,007**
SIA						**0,021**	**0,017**
PGIRLA							-0,004

3.2.2. CoABCMiner Algoritmasının Dengesiz Sınıf Dağılımlı Test Problemleri Üzerindeki Doğruluk Analizi

CoABCMiner algoritması detayları EK-1'de verilen dengesiz sınıf dağılımına sahip 33 test problemi üzerinde çalıştırılmıştır. Dengesiz dağılımlı problemler veri kümesinde her sınıf için yeterli ve eşit sayıda eğitim örneği içermemektedir. Elde edilen sonuçlar ABCMiner ve literatürde verilmiş 16 sınıflandırma algoritmasının sonuçlarıyla karşılaştırılmıştır [60]. CoABCMiner algoritması 5 farklı rastgele üretilmiş başlangıç popülasyonu kullanılarak 5 kat çapraz doğrulama işlemi ile her bir veri kümesi için 25 kez çalıştırılmıştır. Elde edilen eğitim ve test doğruluklarının ortalaması alınmıştır. Algoritma veri kümesi eğitim doğruluk değerleri Tablo 3.15 ve Tablo 3.16'da, test doğruluk değerleri ise Tablo 3.17 ve Tablo 3.18'de verilmiştir. Tablolarda problemler için sonuç elde edilemeyen algoritmaların karşısına (-) işareti konulmuştur.

Tablo 3.15 ve 3.16'da verilen eğitim doğruluk değerleri incelendiğinde CoABCMiner algoritması, 3,61 ortalama derecesi ile ObliqueDT ve SIA algoritmasından sonra 18 algoritma içinde 3. sırada yer almıştır. ObliqueDT ve SIA algoritmalarının bir çok problemi %100 doğruluk oranıyla öğrenmesi eğitim başarısını yüksek göstermiştir. Ancak bu yüksek eğitim başarısı algoritmaların aşırı öğrenme davranışı göstermesinden dolayı kaynaklanmıştır. Ayrıca CoABCMiner algoritması 4,12 ortalama derecesine sahip ABCMiner algoritmasından da daha yüksek başarı oranı elde etmiştir.

Eğitim sonuçlarından görüleceği üzere CoABCMiner, 2 problem (Süsen0 ve Yeni Tiroit 1) için en yüksek eğitim doğruluğu ile birinci sırada, 11 problem için ise ObliqueDT ve SIA'dan sonra ikinci sırada yer almıştır. Bu 11 problemden Maya1, Ecoli2, Cam6, Ecoli4, Maya2vs8, Maya5 ve Maya6 veri kümelerinde CoABCMiner algoritması üçüncü

sıradaki ABCMiner algoritmasından daha yüksek eğitim doğruluğu başarısına sahiptir. CoABCMiner Yeni Tiroit2 veri kümesi için üçüncü sıradaki OIGA algoritmasından sonra ikinci sırada bulunmaktadır. CoABCMiner ve ABCMiner Ecoli0vs1 veri kümesinde benzer oranda eğitim doğruluğu göstermiş ve onlardan sonra PGIRLA algoritması üçüncü sırada yer almıştır. Cam4 veri kümesi için CoABCMiner algoritmasından sonra ise XCS algoritması gelmektedir. Eğitim sonuçları incelendiğinde geriye kalan diğer 20 veri kümesi için CoABCMiner algoritmasının ortalama başarı sergilediği görülmektedir. Bununla birlikte Tablo 3.17 ve 3.18'de verilen algoritmaların test veri kümeleri üzerinde elde ettiği sonuçlar, CoABCMiner algoritmasının başarısını daha net ortaya koymaktadır. Tablolardan görüldüğü üzere CoABCMiner algoritması 33 problem için 1,82 ortalama sıra değeriyle eğitim doğrulukları arasında daha yüksek değere sahip olan ObliqueDT ve SIA algoritmalarını geride bırakmış ve test problemleri açısından en yüksek ortalama derecesine sahip birinci algoritma olmuştur. ObliqueDT ve SIA algoritmalarının test işleminde düşük başarısı, bu algoritmaların aşırı öğrenme karakteristiği göstermesi ve veri için aşırı özelleşmiş sınıflandırma modelleri ortaya koymasından kaynaklanmaktadır. Yani genelleştirme yeteneğinin zayıfladığı görülmektedir. Sonuçlar değerlendirildiğinde CoABCMiner algoritması dengesiz dağılımlı test problemlerinde yüksek başarı gösteren modeller ortaya koymaktadır.

Test doğrulukları incelendiğinde CoABCMiner algoritması; Wisconsin, Cam0, Taşıtlar0, Taşıtlar2, Yeni Tiroit2, Segmentasyon0, Vowel0, Maya6 ve Abalone19 veri kümeleri hariç olmak üzere geriye kalan diğer 24 veri kümesi üzerinde birinci olmuştur. CoABCMiner özellikle Maya1, Abalone0vs18 ve Diyabet veri kümeleri için rakip algoritmalara göre yüksek başarı oranları elde etmiştir. CoABCMiner algoritmasının elde ettiği doğruluk oranları bir sonraki algoritma ile karşılaştırıldığında aralarındaki farka göre şu şekilde sıralanabilir:

1. Maya1: ABCMiner'dan %6,55 daha yüksek başarı ve %76,31 test doğruluğu.
2. Abalone9vs18: ABCMiner'dan %5,77 daha yüksek başarı ve %93,43 test doğruluğu.
3. Diyabet: DT-GA'dan %5,36 daha yüksek başarı ve %75,15 test doğruluğu.
4. Ecoli2: ABCMiner'dan %4,87 daha yüksek başarı ve %94,05 test doğruluğu.

5. Taşıtlar1: ABCMiner'dan %4,52 daha yüksek başarı ve %76,10 test doğruluğu.
6. Cam5: ObliqueDT algoritmasından %4,39 daha yüksek başarı ve %98,04 test doğruluğu.
7. Haberman: ABCMiner'dan %3,92 daha yüksek başarı ve %73,38 test doğruluğu.
8. Taşıtlar3: ABCMiner'dan %3,35 daha yüksek başarı ve %76,17 test doğruluğu.
9. Ecoli3: ABCMiner'dan %3,24 daha yüksek başarı ve %90,12 test doğruluğu.
10. Cam2: ABCMiner'dan %3,15 daha yüksek başarı ve %88,68 test doğruluğu.
11. Sayfa-Blokları0: DT-GA'dan %2,72 daha yüksek başarı ve %94,90 test doğruluğu.
12. Ecoli4: ABCMiner'dan %2,68 daha yüksek başarı ve %97,09 test doğruluğu.
13. Maya2vs8: ABCMiner'dan %2,66 daha yüksek başarı ve %97,26 test doğruluğu.
14. Maya5: ABCMiner'dan %2,2 daha yüksek başarı ve %98,06 test doğruluğu.
15. Ecoli1: CORE'dan %2,17 daha yüksek başarı ve %90,96 test doğruluğu.
16. Cam6: XCS'dan %1,52 daha yüksek başarı ve %95,52 test doğruluğu.
17. YeniTiroit1: Gassist algoritmasından %1,28 daha yüksek başarı ve %97,49 test doğruluğu.
18. Cam4: SIA'dan %0,86 daha yüksek başarı ve %96,27 test doğruluğu.
19. Maya4: ABCMiner'dan %0,5 daha yüksek başarı ve %95,78 test doğruluğu.

XCS algoritması Wisconsin için %96,97; Cam0 için %83,29; Taşıtlar0 için %95,37 ve Taşıtlar2 için %97,06 test oranıyla, Gassist algoritması Yeni Tiroit2 için %97,67 test oranıyla, SIA algoritması Segmentasyon0 için %99,44 ve Vowel0 için %100 test oranıyla, ABCMiner algoritması ise Maya6 için %97,64 ve Abalone19 için %99,23 test oranıyla CoABCMiner ve diğer algoritmaları geçerek birinci algoritma olmuştur.

Tablo 3.13. CoABCMiner kontrol algoritması ile diğer algoritmaların test doğruluk değerlerinin Friedman testi ile eşli analizi ve Bonferroni-Dunn, Holm, Hochberg, Hommel, Holland, Rom, Finner ve Li son düzeltme metotları ile güncellenmiş p değerleri ($\alpha = 0,05$) [133].

i	Algoritma Adı	$z = (R_0 - R_i)/SE$	p	p_{Bonf}	p_{Holm}	$p_{Hochberg}$	p_{Hommel}	$p_{Holland}$	p_{Rom}	p_{Finner}	p_{Li}
1	ABCMiner	3,803044	**0,000143**	**0,001001**	**0,001001**	**0,001001**	**0,000858**	**0,001**	**0,000951**	**0,001**	**0,000194**
2	LDWPSO	3,763012	**0,000168**	**0,001175**	**0,001007**	**0,001007**	**0,001007**	**0,001007**	**0,000958**	**0,001**	**0,000228**
3	PGIRLA	3,042435	**0,002347**	**0,016427**	**0,011734**	**0,011734**	**0,011198**	**0,011679**	**0,011159**	**0,005467**	**0,003171**
4	HIDER	2,842275	**0,004479**	**0,031355**	**0,017917**	**0,017917**	**0,017917**	**0,017797**	**0,017084**	**0,007826**	**0,006036**
5	CORE	1,841474	0,065552	0,458865	0,196656	0,196656	0,196656	0,184047	0,196656	0,090554	0,081612
6	C4 5	1,200961	0,229766	1,608364	0,459533	0,262332	0,262332	0,40674	0,262332	0,262561	0,237501
7	SIA	1,120897	0,262332	1,836322	0,459533	0,262332	0,262332	0,40674	0,262332	0,262561	0,262332

Tablo 3.14. Genel karşılaştırma tablosu: Eğitim doğruluğu ve test doğruluğu ortalamaları, standart sapmaları, keşfedilen kural ve koşul ortalama sayıları, çalışma süreleri (msn.).

Ölçüt	CoABCMiner	C4.5	ABCMiner	LDWPSO	CORE	SIA	PGIRLA	HIDER
Eğitim Doğruluğu	%91,99 (2)	%89,84 (4)	%86,93 (5)	%86,04 (6)	%81,62 (8)	**%96,66 (1)**	%83,40 (7)	%90,26 (3)
Eğ. Doğ. St. Sap.	%0,67 (2)	%1,79 (6)	%1,59 (5)	%2,69 (8)	%1,50 (4)	**%0,48 (1)**	%2,47 (7)	%1,32 (3)
Test Doğruluğu	**%87,08 (1)**	%84,86 (2)	%77,80 (7)	%78,29 (6)	%77,48 (8)	%82,51 (3)	%78,74 (5)	%78,94 (4)
Test Doğ. St. Sap.	%5,47 (2)	%5,77 (3)	%8,39 (7)	%8,56 (8)	**%5,32 (1)**	%6,10 (4)	%7,04 (6)	%6,12 (5)
Kural Sayısı	13,69 (5)	11,89 (4)	**5,66 (1)**	5,85 (2)	7,44 (3)	133,84 (7)	-	13,77 (6)
Koşul Sayısı	71,4 (5)	27,3 (3)	12,1 (2)	**11,5 (1)**	34,1 (4)	1479,1 (8)	172,4 (6)	198 (7)
Çalışma Süresi	32848 (4)	**536 (1)**	1551350 (7)	2461094 (8)	360314 (6)	167406 (5)	3214 (2)	28884 (3)
Ortalama	3,00 (1)	3,29 (2)	4,86 (5)	5,57 (7)	4,86 (5)	4,14 (3)	5,57 (7)	4,17 (4)

Tablo 3.15. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama eğitim doğrulukları.

Veri Kümesi	CoABCMiner	ABCMiner	COGIN*	CORE*	DMEL*	DT-GA*	Gassist*	GIL*	HIDER*
Cam1	86,82% (4)	84,53% (6)	60,91% (13)	51,04% (14)	25,00% (17)	71,15% (8)	88,93% (3)	70,00% (10)	86,19% (5)
Ecoli0vs1	99,09% (2)	99,09% (2)	80,93% (11)	98,69% (6)	25,01% (13)	98,69% (6)	98,69% (6)	90,87% (9)	97,52% (8)
Wisconsin Meme K	98,40% (7)	97,35% (9)	98,43% (5)	93,89% (16)	52,88% (18)	97,25% (10)	98,74% (3)	97,52% (8)	97,03% (11)
Diyabet	80,36% (4)	81,20% (3)	38,87% (16)	63,74% (12)	25,16% (17)	78,99% (5)	77,69% (7)	54,52% (15)	71,93% (8)
Süsen0	**100,00% (1)**	**100,00% (1)**	94,27% (3)	**100,00% (1)**	75,16% (5)	**100,00% (1)**	**100,00% (1)**	94,81% (2)	**100,00% (1)**
Cam0	85,35% (6)	88,04% (5)	66,68% (12)	67,93% (11)	0,00% (17)	89,78% (4)	90,66% (3)	78,21% (8)	84,36% (7)
Maya1	78,08% (2)	77,22% (3)	11,46% (16)	47,63% (9)	0,00% (17)	68,32% (5)	66,87% (6)	42,79% (13)	45,66% (10)
Taşıtlar1	79,75% (4)	81,46% (3)	61,07% (10)	38,03% (14)	5,37% (17)	69,89% (7)	68,57% (9)	68,95% (8)	55,20% (11)
Taşıtlar2	93,84% (8)	94,79% (7)	88,65% (12)	38,22% (16)	49,51% (15)	97,75% (4)	97,87% (3)	90,22% (11)	81,18% (13)
Taşıtlar3	79,07% (5)	81,73% (4)	58,08% (10)	18,94% (14)	15,81% (15)	71,92% (7)	70,38% (8)	70,26% (9)	55,31% (11)
Haberman	78,12% (4)	79,08% (3)	21,86% (16)	47,47% (11)	38,08% (15)	40,83% (13)	66,81% (6)	48,87% (10)	41,69% (12)
Cam0123vs456	98,04% (4)	97,27% (6)	88,52% (15)	87,26% (16)	69,50% (17)	92,34% (12)	98,71% (3)	95,39% (8)	97,31% (5)
Taşıtlar0	89,86% (8)	92,15% (7)	68,72% (14)	19,38% (16)	3,88% (17)	94,52% (4)	95,69% (3)	80,40% (11)	70,25% (13)
Ecoli1	93,29% (5)	94,41% (4)	59,87% (15)	89,88% (10)	18,30% (17)	90,81% (9)	94,60% (3)	69,65% (14)	77,94% (12)
Yeni Tiroit2	99,98% (2)	99,05% (5)	86,20% (16)	94,45% (14)	81,34% (17)	94,85% (11)	98,47% (8)	94,68% (13)	95,16% (10)
Yeni Tiroit1	**100,00% (1)**	99,42% (4)	83,82% (15)	92,27% (10)	83,57% (16)	96,96% (7)	99,86% (2)	88,46% (14)	95,70% (8)
Ecoli2	96,86% (2)	96,74% (3)	38,05% (16)	79,22% (10)	0,00% (17)	86,92% (8)	96,03% (4)	61,04% (13)	59,29% (14)
Segmentasyon0	98,98% (7)	90,74% (11)	64,34% (14)	0,00% (15)	0,00% (15)	98,99% (6)	99,12% (4)	93,64% (10)	86,94% (12)
Cam6	99,51% (2)	99,02% (3)	96,43% (10)	88,30% (15)	57,08% (16)	93,25% (14)	97,37% (8)	**100,00% (1)**	94,44% (12)
Maya3	95,76% (4)	95,81% (3)	60,15% (14)	72,57% (12)	0,00% (18)	87,28% (10)	90,85% (8)	92,22% (7)	60,01% (15)
Ecoli3	93,75% (3)	94,94% (2)	64,11% (10)	59,86% (13)	7,98% (16)	79,64% (5)	84,06% (4)	72,29% (8)	64,02% (11)
Sayfa-Blokları0	95,27% (5)	94,78% (6)	56,12% (17)	64,31% (15)	0,95% (18)	95,27% (4)	82,93% (9)	75,24% (12)	90,19% (7)
Vowel0	99,06% (4)	97,23% (7)	51,76% (16)	78,74% (11)	18,83% (17)	99,96% (2)	98,87% (5)	70,44% (14)	88,37% (10)
Cam2	93,72% (3)	94,72% (2)	31,54% (8)	21,58% (10)	0,00% (13)	82,65% (6)	7,56% (12)	83,83% (5)	9,17% (11)
Ecoli4	99,52% (2)	98,74% (3)	51,01% (15)	86,63% (10)	8,53% (16)	94,10% (5)	97,44% (4)	88,48% (9)	82,61% (11)
Cam4	99,91% (2)	97,62% (4)	78,70% (8)	68,66% (12)	10,17% (16)	62,19% (14)	95,49% (7)	96,90% (5)	67,95% (13)
Abalone9vs18	94,08% (3)	95,12% (2)	53,60% (9)	37,57% (12)	52,90% (10)	62,76% (6)	62,27% (7)	68,59% (5)	18,83% (16)
Cam5	99,98% (2)	97,99% (4)	84,40% (8)	87,44% (7)	0,00% (16)	63,01% (11)	66,90% (9)	99,20% (3)	61,27% (12)
Maya2vs8	98,66% (2)	96,93% (3)	74,79% (7)	74,01% (9)	25,65% (14)	20,91% (15)	78,21% (6)	84,81% (4)	72,39% (11)
Maya4	96,02% (4)	96,41% (3)	25,44% (12)	16,80% (15)	0,00% (17)	60,82% (8)	36,02% (9)	74,31% (7)	17,30% (14)
Maya5	98,32% (2)	97,17% (3)	46,82% (10)	15,94% (13)	0,00% (15)	85,50% (8)	89,81% (5)	85,87% (7)	8,93% (14)
Maya6	97,86% (2)	97,64% (3)	40,45% (9)	5,34% (12)	0,00% (13)	66,51% (8)	0,00% (13)	71,97% (7)	0,00% (13)
Abalone19	98,62% (3)	99,23% (2)	0,00% (9)	0,00% (9)	7,92% (8)	0,00% (9)	0,00% (9)	81,27% (6)	0,00% (9)
Sıra Ortalaması	3,61	4,12	11,85	11,82	15,30	7,64	5,97	8,67	10,61

Tablo 3.16. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama eğitim doğrulukları (devamı).

Veri Kümesi	ILGA*	ObliqueDT*	OCEC*	OIGA*	PGIRLA*	SIA*	Target*	UCS*	XCS*
Cam1	38,72% (16)	**100,00% (1)**	70,44% (9)	48,13% (15)	75,47% (7)	**100,00% (1)**	66,75% (11)	65,12% (12)	98,90% (2)
Ecoli0vs1	98,69% (6)	**100,00% (1)**	90,12% (10)	98,85% (4)	98,86% (3)	**100,00% (1)**	98,11% (7)	31,12% (12)	98,85% (5)
Wisconsin Meme K	94,57% (15)	**100,00% (1)**	95,51% (13)	94,92% (14)	91,37% (17)	99,95% (2)	95,98% (12)	98,42% (6)	98,49% (4)
Diyabet	68,29% (11)	**100,00% (1)**	55,02% (14)	69,36% (10)	71,78% (9)	**100,00% (1)**	57,25% (13)	78,91% (6)	91,05% (2)
Süsen0	**100,00% (1)**	**100,00% (1)**	93,44% (4)	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**	**100,00% (1)**
Cam0	74,42% (10)	**100,00% (1)**	77,76% (9)	54,49% (14)	64,10% (13)	**100,00% (1)**	31,29% (16)	33,07% (15)	95,49% (2)
Maya1	41,93% (14)	**100,00% (1)**	43,79% (12)	50,49% (8)	57,00% (7)	**100,00% (1)**	13,56% (15)	74,58% (4)	45,11% (11)
Taşıtlar1	43,31% (13)	**100,00% (1)**	70,43% (6)	55,17% (12)	22,19% (15)	**100,00% (1)**	11,04% (16)	78,28% (5)	90,01% (2)
Taşıtlar2	94,91% (6)	**100,00% (1)**	90,84% (10)	93,00% (9)	18,65% (17)	**100,00% (1)**	49,57% (14)	96,48% (5)	99,71% (2)
Taşıtlar3	45,98% (13)	**100,00% (1)**	72,15% (6)	51,34% (12)	8,20% (16)	**100,00% (1)**	0,00% (17)	88,53% (3)	90,04% (2)
Haberman	18,58% (17)	**98,99% (1)**	49,08% (9)	14,85% (18)	55,11% (8)	98,49% (2)	38,57% (14)	55,39% (7)	68,71% (5)
Cam0123vs456	93,62% (11)	**100,00% (1)**	95,35% (9)	96,57% (7)	94,20% (10)	**100,00% (1)**	91,57% (13)	88,94% (14)	99,11% (2)
Taşıtlar0	86,11% (9)	**100,00% (1)**	81,12% (10)	94,12% (5)	72,44% (12)	**100,00% (1)**	58,24% (15)	92,96% (6)	99,98% (2)
Ecoli1	91,28% (7)	**100,00% (1)**	69,87% (13)	92,04% (6)	90,83% (8)	**100,00% (1)**	88,93% (11)	56,94% (16)	94,60% (2)
Yeni Tiroit2	98,54% (7)	**100,00% (1)**	93,12% (15)	99,86% (3)	98,55% (6)	**100,00% (1)**	95,37% (9)	94,77% (12)	99,57% (4)
Yeni Tiroit1	99,20% (5)	**100,00% (1)**	88,71% (13)	99,57% (3)	98,78% (6)	**100,00% (1)**	93,78% (9)	92,23% (11)	91,64% (12)
Ecoli2	91,53% (6)	**100,00% (1)**	61,10% (12)	88,41% (7)	92,79% (5)	**100,00% (1)**	83,35% (9)	64,48% (11)	38,24% (15)
Segmentasyon0	98,94% (8)	**100,00% (1)**	93,73% (9)	99,08% (5)	0,00% (15)	**100,00% (1)**	82,79% (13)	99,28% (3)	99,47% (2)
Cam6	95,57% (11)	**100,00% (1)**	97,87% (5)	97,36% (9)	98,70% (4)	**100,00% (1)**	93,40% (13)	97,69% (7)	97,81% (6)
Maya3	67,24% (13)	**100,00% (1)**	92,34% (6)	87,01% (11)	88,37% (9)	99,77% (2)	53,52% (16)	93,31% (5)	17,25% (17)
Ecoli3	60,74% (12)	**100,00% (1)**	72,32% (7)	72,29% (9)	72,83% (6)	**100,00% (1)**	0,00% (17)	50,07% (14)	42,53% (15)
Sayfa-Blokları0	65,31% (14)	99,82% (2)	75,87% (11)	82,82% (10)	74,97% (13)	**99,89% (1)**	58,35% (16)	95,54% (3)	86,25% (8)
Vowel0	88,92% (9)	**100,00% (1)**	75,16% (12)	93,80% (8)	69,24% (15)	**100,00% (1)**	71,22% (13)	99,56% (3)	97,56% (6)
Cam2	0,00% (13)	**100,00% (1)**	83,89% (4)	0,00% (13)	0,00% (13)	**100,00% (1)**	0,00% (13)	41,31% (7)	30,69% (9)
Ecoli4	90,79% (8)	**100,00% (1)**	88,48% (9)	91,30% (7)	92,77% (6)	**100,00% (1)**	71,58% (13)	77,40% (12)	61,05% (14)
Cam4	72,01% (11)	**100,00% (1)**	96,15% (6)	72,35% (10)	15,27% (15)	**100,00% (1)**	0,00% (17)	74,29% (9)	97,95% (3)
Abalone9vs18	32,13% (13)	**100,00% (1)**	69,77% (4)	43,58% (11)	23,01% (15)	**100,00% (1)**	10,28% (17)	59,47% (8)	29,97% (14)
Cam5	54,21% (13)	**100,00% (1)**	95,43% (6)	95,61% (5)	7,07% (15)	**100,00% (1)**	0,00% (16)	63,51% (10)	52,90% (14)
Maya2vs8	31,21% (13)	**100,00% (1)**	84,79% (5)	38,98% (12)	15,81% (16)	**100,00% (1)**	74,01% (9)	74,33% (8)	73,24% (10)
Maya4	34,56% (11)	**100,00% (1)**	74,60% (6)	35,67% (10)	19,54% (13)	99,26% (2)	0,00% (17)	82,19% (5)	3,12% (16)
Maya5	46,21% (11)	**100,00% (1)**	86,08% (6)	69,41% (9)	30,66% (12)	**100,00% (1)**	0,00% (15)	92,97% (4)	0,00% (15)
Maya6	10,33% (10)	**100,00% (1)**	72,48% (6)	10,00% (11)	0,00% (13)	95,98% (4)	0,00% (13)	82,48% (5)	0,00% (13)
Abalone19	0,00% (9)	**100,00% (1)**	83,24% (5)	0,00% (9)	0,00% (9)	91,96% (4)	0,00% (9)	49,64% (7)	0,00% (9)
Sıra Ortalaması	10,48	1,03	8,52	9,00	10,58	1,30	13,00	7,76	7,45

Tablo 3.17. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama test doğrulukları.

Veri Kümesi	CoABCMiner	ABCMiner	COGIN*	CORE*	DMEL*	DT-GA*	Gassist*	GIL*	HIDER*
Cam1	**75,43% (1)**	60,11% (10)	43,04% (15)	48,75% (14)	19,76% (18)	65,62% (7)	70,07% (4)	53,14% (12)	64,12% (9)
Ecoli0vs1	**98,73% (1)**	95,18% (12)	79,53% (16)	95,97% (11)	12,65% (18)	98,31% (2)	97,97% (4)	89,20% (14)	96,63% (10)
Wisconsin Meme K	95,29% (8)	96,02% (5)	94,66% (10)	93,77% (13)	53,18% (17)	94,05% (11)	95,23% (9)	96,57% (3)	95,81% (6)
Diyabet	**75,15% (1)**	67,96% (5)	36,95% (16)	60,13% (12)	16,39% (17)	69,79% (2)	65,64% (7)	50,65% (14)	63,23% (8)
Süsen0	**100,00% (1)**	99,87% (2)	91,16% (8)	**100,00% (1)**	72,46% (11)	98,97% (4)	99,49% (3)	90,65% (9)	**100,00% (1)**
Cam0	80,56% (4)	67,79% (10)	56,51% (13)	63,07% (11)	0,00% (18)	81,02% (3)	81,03% (2)	69,32% (8)	69,63% (7)
Maya1	**76,31% (1)**	69,76% (2)	8,21% (17)	48,64% (8)	0,00% (18)	61,25% (4)	61,23% (5)	40,96% (13)	42,31% (10)
Taşıtlar1	**76,10% (1)**	71,58% (2)	51,36% (11)	34,92% (14)	3,56% (17)	58,28% (8)	56,23% (10)	59,84% (6)	44,69% (12)
Taşıtlar2	92,15% (6)	86,39% (11)	83,97% (13)	36,29% (17)	50,17% (15)	94,23% (4)	94,75% (2)	88,31% (8)	75,16% (14)
Taşıtlar3	**76,17% (1)**	72,82% (2)	50,85% (11)	11,02% (16)	12,96% (15)	57,25% (9)	58,83% (8)	62,87% (6)	43,77% (13)
Haberman	**73,38% (1)**	69,46% (2)	13,90% (16)	37,30% (9)	33,56% (13)	35,63% (12)	45,26% (6)	45,18% (8)	32,31% (14)
Cam0123vs456	**93,54% (1)**	86,17% (10)	79,87% (16)	80,87% (13)	63,04% (18)	89,24% (5)	88,57% (6)	83,49% (12)	89,90% (3)
Taşıtlar0	88,86% (6)	80,14% (9)	64,90% (13)	12,83% (17)	1,76% (18)	92,58% (2)	90,77% (3)	75,70% (12)	60,81% (14)
Ecoli1	**90,96% (1)**	86,19% (7)	50,63% (17)	88,79% (2)	15,53% (18)	84,91% (9)	86,22% (6)	62,07% (14)	76,56% (12)
Yeni Tiroit2	97,49% (2)	90,33% (12)	81,94% (16)	88,83% (13)	78,13% (17)	92,17% (7)	**97,67% (1)**	93,51% (4)	87,57% (14)
Yeni Tiroit1	**97,49% (1)**	92,93% (6)	83,96% (14)	91,25% (10)	83,63% (17)	90,86% (11)	96,21% (2)	83,77% (15)	92,32% (7)
Ecoli2	**94,05% (1)**	89,18% (2)	37,37% (16)	78,00% (9)	0,00% (18)	77,55% (10)	87,91% (3)	53,17% (14)	59,37% (12)
Segmentasyon0	98,80% (4)	89,52% (12)	65,13% (15)	0,00% (16)	0,00% (16)	98,19% (7)	98,00% (9)	93,31% (11)	80,39% (14)
Cam6	**95,52% (1)**	91,78% (4)	84,87% (10)	73,70% (17)	50,68% (18)	79,42% (15)	84,74% (11)	88,31% (9)	76,25% (16)
Maya3	**94,92% (1)**	92,29% (2)	54,06% (14)	70,10% (12)	0,00% (18)	82,38% (8)	85,25% (6)	90,36% (4)	52,27% (16)
Ecoli3	**90,12% (1)**	86,88% (2)	56,70% (9)	48,79% (11)	7,30% (17)	72,68% (3)	67,11% (5)	66,32% (6)	45,04% (13)
Sayfa-Blokları0	**94,90% (1)**	91,60% (3)	55,01% (16)	64,92% (13)	0,00% (18)	92,18% (2)	80,87% (10)	74,73% (12)	89,27% (5)
Vowel0	97,71% (2)	95,20% (6)	39,67% (17)	72,60% (12)	16,86% (18)	96,83% (3)	93,60% (7)	62,77% (14)	76,37% (11)
Cam2	**88,68% (1)**	85,53% (2)	0,00% (10)	10,00% (8)	0,00% (10)	52,59% (5)	0,00% (10)	67,11% (3)	0,00% (10)
Ecoli4	**97,09% (1)**	94,41% (2)	27,18% (17)	78,40% (5)	7,56% (18)	82,33% (4)	78,02% (6)	73,38% (9)	69,50% (10)
Cam4	**96,27% (1)**	88,99% (3)	35,79% (13)	56,47% (9)	7,63% (17)	30,09% (14)	62,51% (8)	66,51% (6)	41,55% (11)
Abalone9vs18	**93,43% (1)**	87,66% (2)	20,56% (13)	32,73% (11)	44,67% (7)	44,78% (6)	40,41% (9)	53,50% (4)	18,55% (15)
Cam5	**98,04% (1)**	93,29% (3)	19,75% (12)	73,47% (5)	0,00% (14)	42,25% (9)	13,97% (13)	72,01% (6)	32,87% (11)
Maya2vs8	**97,26% (1)**	94,60% (2)	65,46% (10)	72,66% (4)	25,55% (13)	10,00% (14)	62,74% (11)	71,23% (6)	69,58% (8)
Maya4	**95,78% (1)**	95,28% (2)	8,91% (13)	6,31% (14)	0,00% (16)	39,92% (7)	17,16% (9)	58,91% (4)	6,30% (15)
Maya5	**98,06% (1)**	95,86% (2)	26,56% (12)	9,43% (14)	0,00% (15)	83,67% (3)	72,67% (9)	79,44% (5)	0,00% (15)
Maya6	97,48% (2)	**97,64% (1)**	18,20% (9)	0,00% (10)	0,00% (10)	56,60% (5)	0,00% (10)	56,43% (6)	0,00% (10)
Abalone19	98,56% (2)	**99,23% (1)**	0,00% (7)	0,00% (7)	8,04% (5)	0,00% (7)	0,00% (7)	68,96% (3)	0,00% (7)
Sıra Ortalaması	1,82	4,79	13,18	10,85	15,55	6,73	6,70	8,48	10,70

Tablo 3.18. Dengesiz sınıf dağılımlı veri kümeleri için CoABCMiner ve diğer algoritmaların ortalama test doğrulukları (devamı).

Veri Kümesi	ILGA*	ObliqueDT*	OCEC*	OIGA*	PGIRLA*	SIA*	Target*	UCS*	XCS*
Cam1	25,54% (17)	68,57% (5)	50,79% (13)	37,34% (16)	65,69% (6)	74,51% (3)	64,38% (8)	55,40% (11)	75,07% (2)
Ecoli0vs1	94,51% (13)	96,90% (9)	87,73% (15)	96,99% (7)	97,61% (6)	96,90% (8)	98,28% (3)	20,00% (17)	97,67% (5)
Wisconsin Meme K	90,51% (16)	93,21% (14)	95,38% (7)	91,74% (15)	52,93% (18)	96,61% (2)	93,93% (12)	96,22% (4)	**96,97% (1)**
Diyabet	61,99% (11)	66,94% (6)	50,38% (15)	62,45% (10)	0,00% (18)	63,17% (9)	55,33% (13)	69,14% (3)	68,05% (4)
Süsen0	98,48% (5)	97,89% (7)	89,83% (10)	97,95% (6)	98,97% (4)	**100,00% (1)**	98,97% (4)	98,97% (4)	**100,00% (1)**
Cam0	56,05% (14)	74,53% (6)	68,40% (9)	49,17% (15)	59,51% (12)	77,20% (5)	31,19% (16)	30,93% (17)	**83,29% (1)**
Maya1	38,58% (14)	61,20% (6)	41,15% (12)	47,72% (9)	27,85% (15)	57,08% (7)	14,27% (16)	68,76% (3)	41,59% (11)
Taşıtlar1	32,51% (15)	66,92% (3)	58,95% (7)	43,77% (13)	0,00% (18)	57,71% (9)	8,42% (16)	62,74% (5)	64,06% (4)
Taşıtlar2	86,77% (10)	94,48% (3)	88,41% (7)	88,14% (9)	17,23% (18)	85,09% (12)	49,68% (16)	92,63% (5)	**97,06% (1)**
Taşıtlar3	38,16% (14)	65,21% (4)	65,12% (5)	44,75% (12)	5,30% (17)	53,18% (10)	0,00% (18)	69,14% (3)	59,82% (7)
Haberman	9,89% (17)	59,77% (3)	45,26% (7)	5,00% (18)	17,59% (15)	52,29% (4)	36,49% (11)	47,87% (5)	36,55% (10)
Cam0123vs456	77,59% (17)	87,19% (7)	85,35% (11)	79,99% (15)	80,16% (14)	86,97% (9)	89,53% (4)	87,07% (8)	93,11% (2)
Taşıtlar0	79,73% (10)	90,07% (4)	76,49% (11)	89,00% (5)	15,29% (16)	80,54% (8)	58,10% (15)	88,64% (7)	**95,37% (1)**
Ecoli1	87,52% (3)	81,55% (10)	58,72% (15)	81,44% (11)	85,60% (8)	73,85% (13)	86,64% (5)	58,09% (16)	87,29% (4)
Yeni Tiroit2	90,67% (10)	93,29% (5)	93,51% (4)	86,43% (15)	92,45% (6)	90,37% (11)	91,66% (8)	91,59% (9)	96,49% (3)
Yeni Tiroit1	94,30% (4)	95,65% (3)	83,68% (16)	91,35% (9)	37,98% (18)	91,87% (8)	93,77% (5)	89,55% (13)	90,00% (12)
Ecoli2	76,20% (11)	86,47% (5)	53,49% (13)	79,80% (8)	82,88% (6)	86,90% (4)	82,28% (7)	50,81% (15)	30,82% (17)
Segmentasyon0	98,08% (8)	98,41% (5)	93,37% (10)	98,26% (6)	0,00% (16)	**99,44% (1)**	80,54% (13)	98,88% (3)	98,98% (2)
Cam6	83,30% (13)	82,29% (14)	89,15% (7)	83,50% (12)	91,98% (3)	90,63% (5)	89,66% (6)	88,49% (8)	94,00% (2)
Maya3	63,65% (13)	82,05% (9)	90,55% (3)	80,50% (11)	83,67% (7)	81,71% (10)	53,89% (15)	89,46% (5)	17,18% (17)
Ecoli3	40,23% (15)	67,15% (4)	63,29% (7)	50,84% (10)	42,14% (14)	61,69% (8)	0,00% (18)	46,29% (12)	31,91% (16)
Sayfa-Blokları0	62,49% (14)	90,07% (4)	75,14% (11)	81,62% (9)	45,75% (17)	86,59% (6)	59,99% (15)	85,04% (7)	84,58% (8)
Vowel0	81,71% (10)	95,59% (5)	62,38% (15)	84,52% (9)	60,33% (16)	**100,00% (1)**	71,07% (13)	96,68% (4)	90,81% (8)
Cam2	0,00% (10)	32,05% (6)	65,99% (4)	0,00% (10)	0,00% (10)	19,34% (7)	0,00% (10)	9,61% (9)	0,00% (10)
Ecoli4	58,00% (15)	88,09% (3)	76,06% (7)	75,28% (8)	63,74% (14)	65,21% (13)	67,70% (12)	68,73% (11)	44,37% (16)
Cam4	48,49% (10)	62,70% (7)	69,72% (5)	27,67% (15)	11,40% (16)	95,41% (2)	0,00% (18)	36,12% (12)	85,97% (4)
Abalone9vs18	7,07% (17)	54,11% (3)	48,65% (5)	20,36% (14)	21,19% (12)	40,17% (10)	0,00% (18)	41,36% (8)	14,14% (16)
Cam5	0,00% (14)	93,65% (2)	88,34% (4)	67,62% (8)	0,00% (14)	67,79% (7)	0,00% (14)	33,97% (10)	0,00% (14)
Maya2vs8	0,00% (15)	69,05% (9)	71,45% (5)	0,00% (15)	10,00% (14)	10,00% (14)	72,83% (3)	56,57% (12)	69,65% (7)
Maya4	12,31% (11)	55,56% (6)	58,31% (5)	12,34% (10)	11,21% (12)	26,21% (8)	0,00% (16)	59,96% (3)	0,00% (16)
Maya5	13,69% (13)	80,82% (4)	78,04% (7)	41,32% (10)	28,01% (11)	77,71% (8)	0,00% (15)	78,14% (6)	0,00% (15)
Maya6	0,00% (10)	62,80% (4)	54,24% (7)	0,00% (10)	0,00% (10)	51,47% (8)	0,00% (10)	75,53% (3)	0,00% (10)
Abalone19	0,00% (7)	7,53% (6)	61,72% (4)	0,00% (7)	0,00% (7)	0,00% (7)	0,00% (7)	0,00% (7)	0,00% (7)
Sıra Ortalaması	12,00	5,79	8,58	10,82	12,36	7,21	11,52	8,03	7,70

3.2.3. CoABCMiner Algoritmasının Kontrol Parametre Hassasiyet Analizi

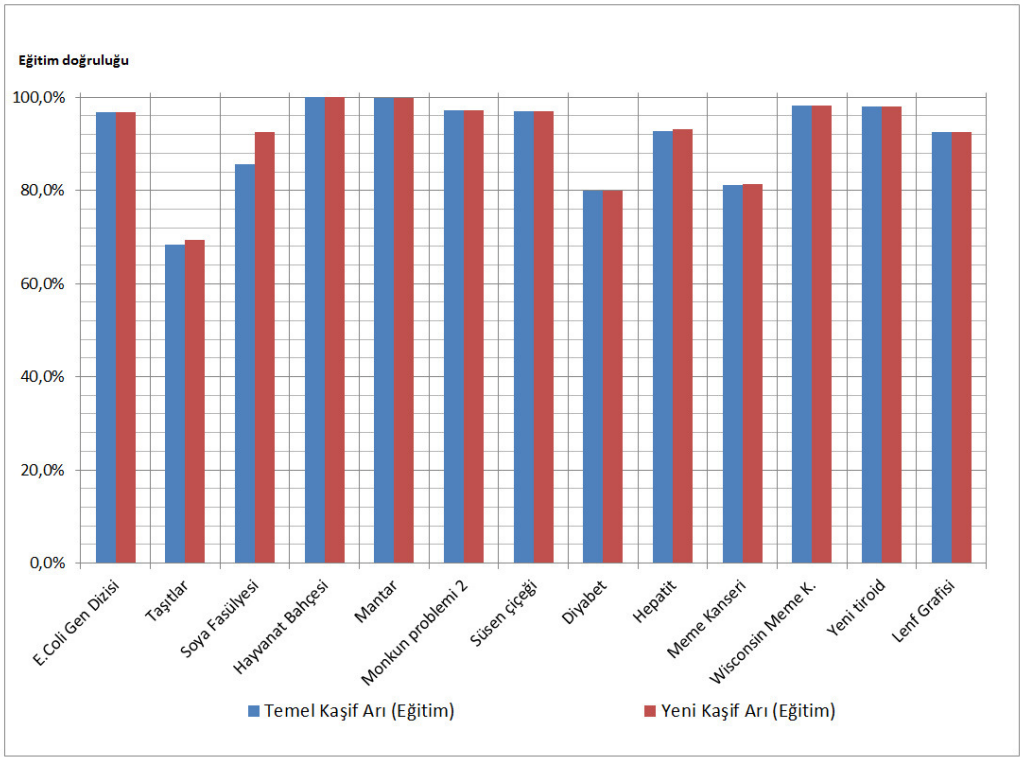
CoABCMiner algoritması, temel ABC algoritmasının sahip olduğu MCN, $Limit$ ve KS parametreleri ile yeni önerilen ve kural içinde öznitelik koşulunun yer alma/almama durumunu belirlemek amacıyla kullanılan $initOranı$ parametresi olmak üzere 4 kontrol parametresi içermektedir. Bu parametrelerin CoABCMiner algoritmasının başarısı üzerindeki etkisi bu bölümde incelenmiştir. Ayrıca bu bölümde CoABCMiner için geliştirilen yeni kaşif arı stratejisinin algoritma üzerindeki etkisi de değerlendirilmiştir. ABC algoritmasında tanımlanan temel kaşif arı işleminde algoritma tükenen yiyecek kaynağı yerine yeni bir rastgele çözüm üretmektedir. Burada önerilen yeni kaşif arı işleminde ise eğitim veri kümesinden en az bir örneği karşılayabilecek şekilde bir rastgele yiyecek kaynağı üretilmektedir.

Yapılan deneylerde Tablo 3.2'de verilmiş parametre değerleri temel alınmış ve sadece etkisi incelenecek parametre değeri değiştirilmiştir. Toplam çevrim sayısı (MCN) parametresi için 3, $Limit$ parametresi için 6, Maksimum Koloni sayısı (KS) parametresi için 14 ve $initOranı$ parametresi için 5 farklı değer ile deneyler tekrarlanmıştır. Algoritma, belirtilen her bir parametre için problemler üzerinde 50 kez çalıştırılmış ve parametre değerleri karşışısında algoritmanın hassasiyet analizi için parametrik olmayan Friedman sıralamalı iki yönlü varyans analizi ile istatistik test yapılmıştır. Sonuçlar karşılaştırılarak kontrol parametrelerinin en başarılı olan aralıkları tespit edilmeye çalışılmıştır.

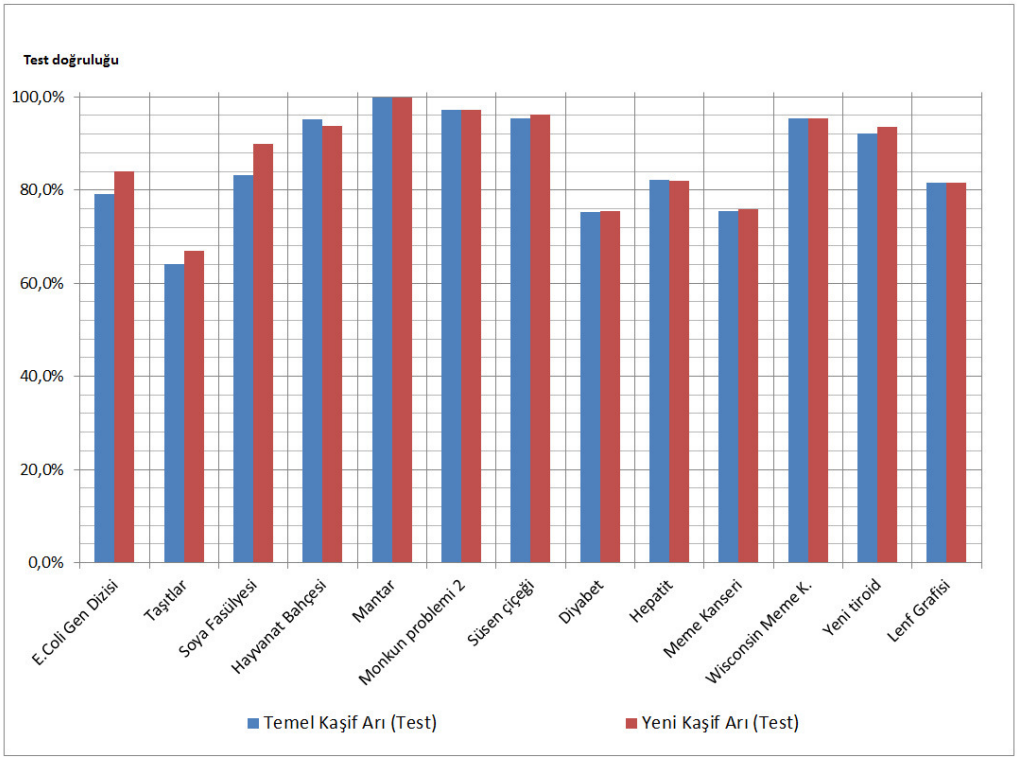
Parametre deney gruplarının orta değerlerinin farklılığının istatistik analizi için Friedman iki yönlü varyans analiz testi yapılmıştır. Parametre aralıkları istatistik testi için kullanılan boş hipotez, kontrol parametresinin değerinin algoritmanın başarısı üzerinde etkisi olmadığını kabul etmektedir.

Yeni kaşif arı stratejisinin temel kaşif arı stratejisine göre avantajı olup olmadığını incelemek amacıyla algoritma her iki kaşif arı yöntemiyle ayrı ayrı çalıştırılmıştır. Wilcoxon çift örneklem sıralama toplamı testi 50 sonuç değeri içeren iki farklı örneklem grubunun istatistiksel açıdan farklı olup olmadığını belirlemek amacıyla veri kümeleri

için yapılmıştır. Wilcoxon testi iki dağılımın ortalamalarının istatistiksel anlamlılık düzeyinde farklı olup olmadığını değerlendirmek için kullanılan parametrik olmayan bir istatistik testidir [82]. Deneylerin eğitim ve test doğruluk ortalamaları grafiği Şekil 3.10 ve 3.11'de, karşılaştırma sonuçları ise Tablo 3.19'da verilmiştir. Tabloda ortalama test doğruluğu ve standart sapma değerlerinin yanındaki verilen (+) işareti elde edilen değerin diğer yönteme göre daha başarılı olduğunu göstermektedir. Grafik incelendiğinde taşıtlar, soya fasülyesi ve hepatit için yeni kaşif arı stratejisi belirgin iyileşmeye sebep olmaktadır. Tabloda ortalama test doğrulukları, test doğruluklarının standart sapmaları ve Wilcoxon testi istatistik sonuçları verilmiştir. Ortalama test sonuçları incelendiğinde temel kaşif arı stratejisi kullanıldığında 5, yeni kaşif arı stratejisi kullanıldığında ise 10 problem için daha yüksek başarı ortalaması elde edilmiştir. Standart sapma değerleri incelendiğinde yeni stratejinin 8 problem için diğer stratejiye göre üstün olduğu görülmektedir. Yeni kaşif arının kullanılması diyabet, süsen çiçeği, lenf grafisi, monkun problemi 2, mantar, yeni tiroid, e.coli gen dizisi, soya fasülyesi, taşıtlar ve kanser veri kümeleri için Şekil 3.10'da görüldüğü üzere eğitim ortalamaları için belirgin bir değişime sebep olmamakla birlikte



Şekil 3.10. CoABCMiner algoritmasında kullanılan yeni kaşif arı ve temel kaşif arı deneyleri eğitim doğrulukları grafiği.



Şekil 3.11. CoABCMiner algoritmasında kullanılan yeni kaşif arı ve temel kaşif arı deneyleri test doğrulukları grafiği.

test ortalamalarında daha yüksek doğruluk elde etmektedir. Wilcoxon test istatistiği değerleri incelendiğinde soya fasülyesi ve taşıtlar veri kümeleri için %5 anlamlılık seviyesine göre istatistik bakımdan yeni ve temel yöntemin birbirinden farklı olduğu tespit edilmiştir. Bu veri kümelerinde yeni yöntem yüksek ortalama değerlerine sahip ve daha başarılıdır. Diğer veri kümeleri için ise örneklem grupları arasında istatistiksel açıdan bir farklılık tespit edilememiştir. Yapılan analiz sonucunda temel kaşif arı yaklaşımının test problemlerinin çoğunluğu için yeterli olduğu sonucu çıkarılmaktadır.

MCN kontrol parametresi için 3 farklı değer (500, 1000, 1500) kullanılarak analiz gerçekleştirilmiştir. Yapılan deneyler sonucu elde edilen ortalama test doğrulukları Tablo 3.20'de verilmiştir. 2 serbestlik derecesi ile Friedman testi istatistik sonuç değerleri Tablo 3.21'de verilmiştir. Şekil 3.12 ve 3.13'te ortalama eğitim ve test doğrulukları grafiği gösterilmektedir. Algoritmanın kural sayısı ve kural başına öğrenilen ortalama koşul sayısı grafikleri ise Şekil 3.14 ve 3.15'te verilmektedir. Şekil 3.12'de görüldüğü üzere beklenildiği gibi MCN değeri yükseldikçe genelde eğitim başarıları yükselmektedir. Şekil 3.13 incelendiğinde genelde test doğruluklarının da arttığı görülmektedir. Bununla

Tablo 3.19. Yeni kaşif arı ile temel kaşif arının Wilcoxon ilişkili iki örneklem testi ile analizi.

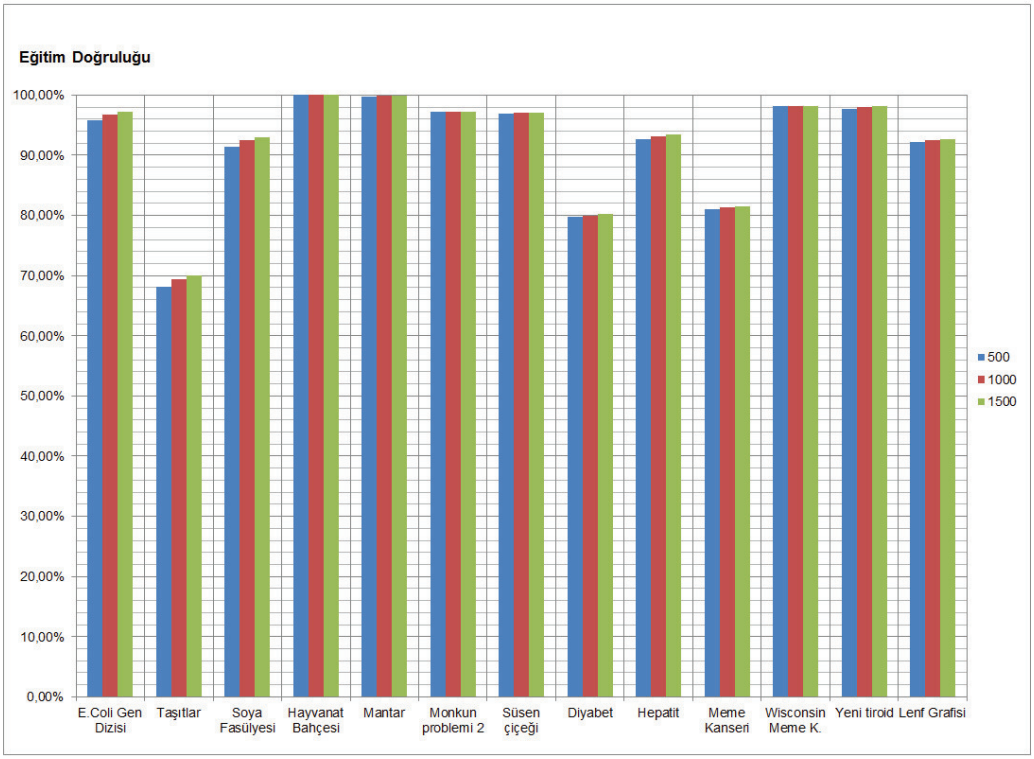
	Ortalama Test Doğrulukları		Test Doğrulukları Standart Sapması		Wilcoxon Testi	
Veri Kümeleri	Temel Kaşif Arı	Yeni Kaşif Arı	Temel Kaşif Arı	Yeni Kaşif Arı	U İstatistik Değeri	p Değeri
Diyabet	%75,29 (-)	**%75,57 (+)**	**%3,88 (+)**	%4,59 (-)	1211	0,7900
Hepatit	**%82,21 (+)**	%82,06 (-)	**%10,87 (+)**	%11,08 (-)	1254,5	0,9779
Süsen Çiçeği	%95,33 (-)	**%96,27 (+)**	%4,71 (-)	**%3,60 (+)**	1146,5	0,4243
Lenf Grafisi	**%81,60 (+)**	**%81,60 (+)**	%9,97 (-)	**%9,10 (+)**	1267	0,9081
Monkun Problemi 2	**%97,27 (+)**	**%97,27 (+)**	**%2,68 (+)**	**%2,68 (+)**	1250	1
Mantar	%99,83 (-)	**%99,86 (+)**	%0,15 (-)	**%0,14 (+)**	1053,5	0,1672
Yeni Tiroid	%92,09 (-)	**%93,51 (+)**	%5,96 (-)	**%5,21 (+)**	1092,5	0,2729
E.Coli Gen Dizisi	%79,22 (-)	**%84,02 (+)**	%13,81 (-)	**%10,44 (+)**	1069	0,2080
Soya Fasülyesi	%83,22 (-)	**%89,98 (+)**	%3,45 (-)	**%3,07 (+)**	178	**0,0000**
Taşıtlar	%64,14 (-)	**%66,93 (+)**	%4,18 (-)	**%3,98 (+)**	737	**0,0004**
Wisconsin Meme K.	**%95,48 (+)**	%95,34 (-)	**%2,05 (+)**	%2,27 (-)	1276,5	0,8557
Kanser	%75,50 (-)	**%75,86 (+)**	**%6,54 (+)**	%6,69 (-)	1219	0,8320
Hayvanat Bahçesi	**%95,22 (+)**	%93,82 (-)	**%6,76 (+)**	%8,30 (-)	1334,5	0,5088
Total	#(+):5	#(+):10	#(+):6	#(+):8		

birlikte boş hipotez 2 serbestlik derecesinde %5 yanılma düzeyi ile sadece mantar, soya fasülyesi ve taşıtlar için reddedilmiştir. Bu veri kümeleri sonuçları için seçilecek maksimum iterasyon sayısının istatistiksel olarak anlamlı ve etkili olduğu belirlenmiştir. Her üç problem için de 1500 iterasyon sayısı en iyi sonucu vermiştir. Kural sayıları incelendiğinde Şekil 3.14'te görüldüğü üzere mantar ve soya fasülyesi için 1500 değerinde keşfedilen kural sayısı azalmıştır.

$Limit$ kontrol parametresi için 6 farklı değer (25, 50, 75, 100, 125, 150) kullanılarak analiz gerçekleştirilmiştir. Yapılan deneyler sonucu elde edilen ortalama test doğrulukları Tablo 3.22'de ve Friedman testi istatistik değerleri Tablo 3.23'te verilmiştir. Şekil 3.16 ve 3.17'de ortalama eğitim ve test doğruluklarının radar ağ grafiği verilmektedir. Radar ağ grafiğinde merkezden dışa doğru doğruluk oranları %0'den %100'e doğru artış

Tablo 3.20. MCN parametre değişimi ortalama test doğrulukları.

Veri Kümeleri	500	1000	1500
Diyabet	%75,83 (2)	%75,57 (3)	**%76,09 (1)**
Hepatit	%81,68 (3)	%82,06 (2)	**%82,61 (1)**
Süsen Çiçeği	%95,07 (3)	%96,27 (2)	**%96,67 (1)**
Lenf Grafisi	%81,85 (2)	%81,60 (3)	**%81,89 (1)**
Monkun Problemi 2	**%97,27 (2)**	**%97,27 (2)**	**%97,27 (2)**
Mantar	%99,76 (3)	%99,86 (2)	**%99,90 (1)**
Yeni Tiroid	%91,94 (3)	%93,51 (2)	**%94,16 (1)**
E.Coli Gen Dizisi	%82,73 (3)	**%84,02 (1)**	%83,96 (2)
Soya Fasülyesi	%88,52 (3)	%89,98 (2)	**%90,74 (1)**
Taşıtlar	%65,39 (3)	%66,93 (2)	**%67,12 (1)**
Wisconsin Meme K.	%95,39 (2)	%95,34 (3)	**%95,45 (1)**
Kanser	**%76,14 (1)**	%75,86 (2)	%75,71 (3)
Hayvanat Bahçesi	**%94,80 (1)**	%93,82 (3)	%94,02 (2)
Ortalama	%86,64 (3)	%87,08 (2)	**%87,35 (1)**



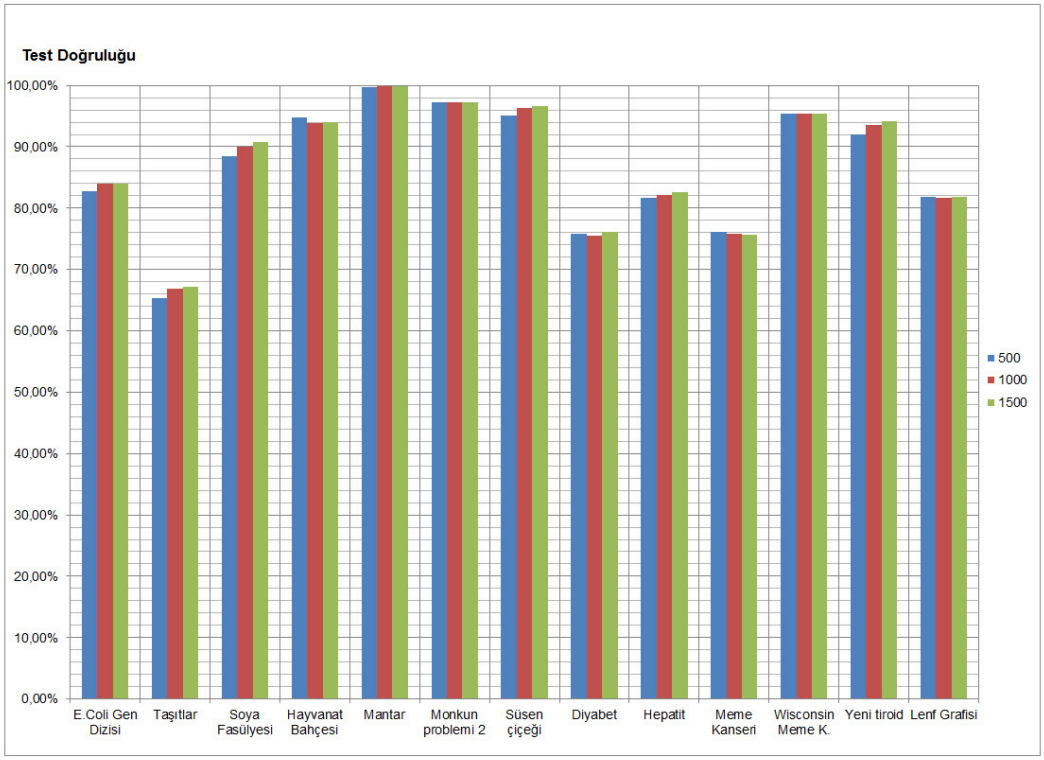
Şekil 3.12. MCN parametre değişimi için ortalama eğitim doğrulukları grafiği.

gösterir. Grafiklerde farklı değerlerin her birinin test problemlerinde elde ettiği doğruluk değişimleri toplu biçimde gösterilmiştir. Algoritmanın 6 farklı değer için elde ettiği kural sayısı ve kural başına öğrenilen ortalama koşul sayısı grafikleri ise Şekil 3.18 ve 3.19'da verilmektedir.

Şekil 3.16'da görüldüğü üzere taşıtlar ve soya fasülyesi eğitim doğruluğu için gözle görülür değişim olmaktadır. Şekil 3.17 dikkate alındığında ise lenf grafisi, e.coli gen dizisi, taşıtlar ve soya fasülyesi olmak üzere 4 problem için test doğruluğunda değişim

Tablo 3.21. MCN parametre değerlerinin test doğrulukları için Friedman testi.

Veri Kümeleri	sd	χ^2	p değeri
Diyabet	2	0,76	0,683861
Hepatit	2	0,39	0,822835
Süsen Çiçeği	2	2,91	0,2334
Lenf Grafisi	2	0,03	0,985112
Monkun Problemi 2	2	0	NaN
Mantar	2	13,23	**0,00134**
Newthyroid	2	2,73	0,255381
E.Coli Gen Dizisi	2	0,09	0,955997
Soya Fasülyesi	2	6,87	**0,032225**
Taşıtlar	2	7,33	**0,025604**
Wisconsin Meme K.	2	0,39	0,822835
Kanser	2	0,57	0,752014
Hayvanat Bahçesi	2	0,39	0,822835



Şekil 3.13. MCN parametre değişimi için ortalama test doğrulukları grafiği.

farkedilmektedir. Limit değerleri arasında 100 değeri ortalama test doğruluğu için sıralamada en başarılı sonucu vermektedir (Tablo 3.22). Kural sayıları bakımından sonuçlar (Şekil 3.18) incelendiğinde $Limit$ değeri hayvanat bahçesi, monkun problemi 2, süsen çiçeği haricindeki veri kümeleri için keşfedilen kural sayılarında değişim gözlenmektedir. Koşul sayılarındaki değişim (Şekil 3.19) özellikle taşıtlar ve soya fasülyesi için belirgindir. Yapılan Friedman testine göre $Limit$ parametresinin aldığı değer 5 serbestlik derecesi ile %5 yanılma düzeyinde sadece mantar, soya fasülyesi ve taşıtlar veri kümeleri için istatistiksel olarak etkili olmuştur (Tablo 3.23).

KS kontrol parametresinin etkisini görmek amacıyla 14 farklı değer (20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150) kullanılarak analiz gerçekleştirilmiştir. Yapılan deneyler sonucu elde edilen ortalama test doğrulukları Tablo 3.24'te, Friedman testi sonuçları Tablo 3.25'te verilmiştir. Şekil 3.20 ve 3.21'de deneylerin ortalama eğitim ve test doğruluklarının radar ağ grafiği gösterilmiştir. Kural ve koşul sayılarındaki değişimler ise Şekil 3.22 ve 3.23'te verilmektedir.

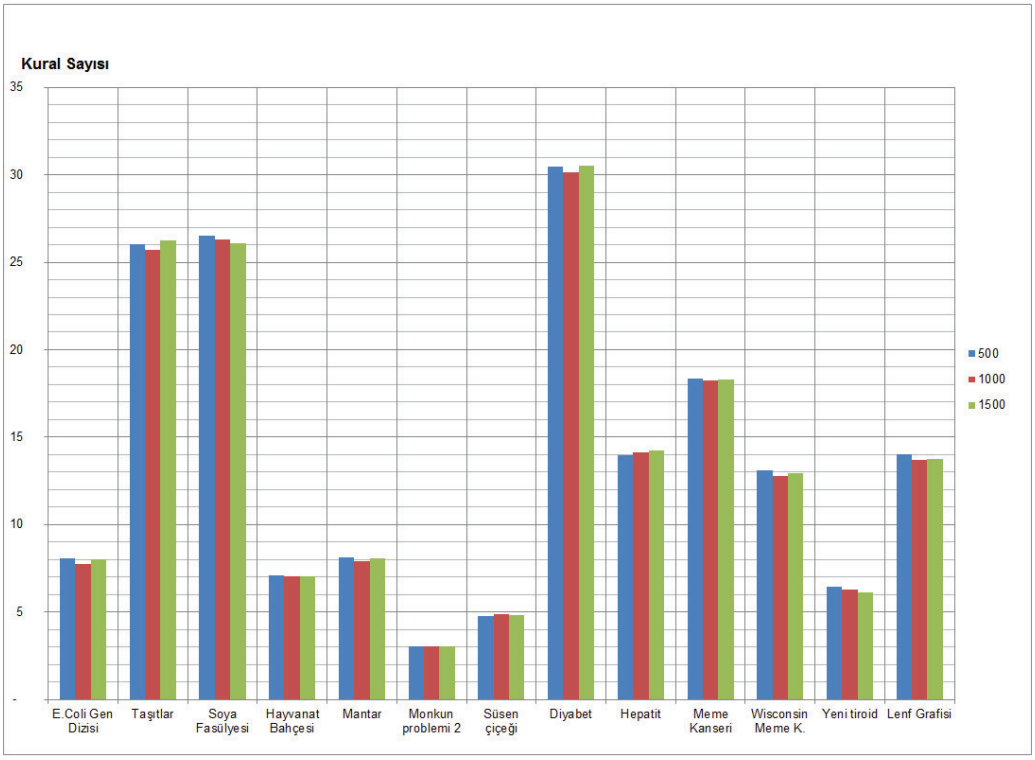
Şekil 3.20 incelendiğinde taşıtlar ve soya fasülyesi eğitim doğrulukları üzerinde belirgin,

Tablo 3.22. *Limit* parametre değişimi ortalama test doğrulukları.

Veri Kümeleri	25	50	75	100	125	150
Diyabet	%75,83 (3)	**%76,32 (1)**	%75,83 (2)	%75,57 (5)	%75,70 (4)	%75,26 (6)
Hepatit	%80,98 (5)	%81,55 (4)	%81,91 (3)	%82,06 (2)	**%82,09 (1)**	%80,91 (6)
Süsen Çiçeği	%95,33 (4)	%95,07 (5)	%95,47 (3)	%96,27 (2)	**%96,40 (1)**	%95,07 (6)
Lenf Grafisi	%79,61 (6)	**%82,21 (1)**	%81,90 (3)	%81,60 (4)	%82,06 (2)	%80,40 (5)
Monkun Problemi 2	**%97,27 (3)**	**%97,27 (3)**	**%97,27 (3)**	**%97,27 (3)**	**%97,27 (3)**	**%97,27 (3)**
Mantar	%99,47 (6)	%99,69 (5)	%99,79 (4)	%99,86 (2)	**%99,87 (1)**	%99,85 (3)
Yeni Tiroid	%92,86 (2)	%92,04 (5)	%92,67 (4)	**%93,51 (1)**	%92,83 (3)	%91,99 (6)
E Coli Gen Dizisi	%77,64 (6)	%80,36 (4)	%81,22 (2)	**%84,02 (1)**	%79,78 (5)	%80,73 (3)
Soya Fasülyesi	%85,09 (6)	%86,32 (5)	%88,85 (4)	%89,98 (3)	%90,48 (2)	**%91,80 (1)**
Taşıtlar	%64,82 (5)	%64,12 (6)	%65,25 (4)	**%66,93 (1)**	%65,75 (2)	%65,29 (3)
Wisconsin Meme K	%95,40 (3)	%95,31 (6)	%95,62 (2)	%95,34 (5)	**%95,65 (1)**	%95,34 (4)
Kanser	%75,79 (2)	%74,71 (6)	%75,72 (3)	**%75,86 (1)**	%75,21 (5)	%75,43 (4)
Hayvanat Bahçesi	**%95,62 (1)**	%94,20 (3)	%93,65 (5)	%93,82 (4)	%93,22 (6)	%94,80 (2)
Ortalama	%85,82 (6)	%86,09 (5)	%86,55 (3)	**%87,08 (1)**	%86,64 (2)	%86,47 (4)

Tablo 3.23. *Limit* parametre değişimi test doğrulukları için Friedman testi.

Veri Kümeleri	sd	χ^2	p değeri
Diyabet	5	4,014286	0,547361
Hepatit	5	1,351429	0,929552
Süsen Çiçeği	5	3,885714	0,565985
Lenf Grafisi	5	3,828571	0,574352
Monkun Problemi 2	5	0	NaN
Mantar	5	43,522857	**0**
Newthyroid	5	2,594286	0,762233
E.Coli Gen Dizisi	5	5,371429	0,37225
Soya Fasülyesi	5	93,885714	**0**
Taşıtlar	5	13,591429	**0,018424**
Wisconsin Meme K.	5	1,337143	0,931064
Kanser	5	2,634286	0,756149
Hayvanat Bahçesi	5	3,437143	0,632919

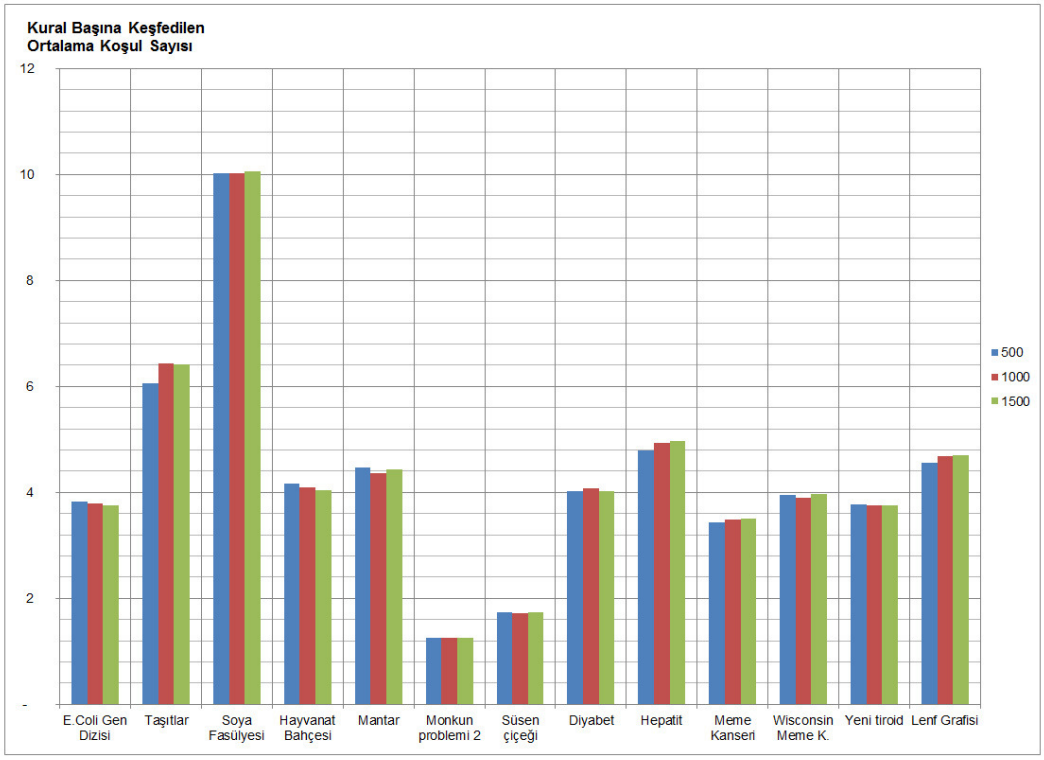


Şekil 3.14. MCN parametre değişimi için ortalama kural sayısı grafiği.

lenf grafisi ve e.coli gen dizisi eğitim doğruluklarında ise daha az bir değişim yaşandığı görülmektedir. Şekil 3.21 incelendiğinde ise e.coli gen dizisi, taşıtlar ve soya fasülyesi test doğrulukları KS değeri ile değişmektedir. Yiyecek kaynağı (KS) parametre değerleri arasında test doğrulukları bakımından en yüksek ortalama 110 değeri için elde edilmiştir(Tablo 3.24).

Kural sayıları KS yiyecek kaynağı değerinden doğrudan etkilenmektedir (Şekil 3.22). Kural başına öğrenilen ortalama koşul sayılarında ise hayvanat bahçesi, hepatit, kanser, Wisconsin, yeni tiroit ve lenf grafisi için değişim belirgindir (Şekil 3.23). Yapılan Friedman testine göre KS parametresi %5 yanılma düzeyinde sadece mantar, soya fasülyesi ve taşıtlar veri kümeleri için istatistiksel olarak etkili olmuştur (Tablo 3.25).

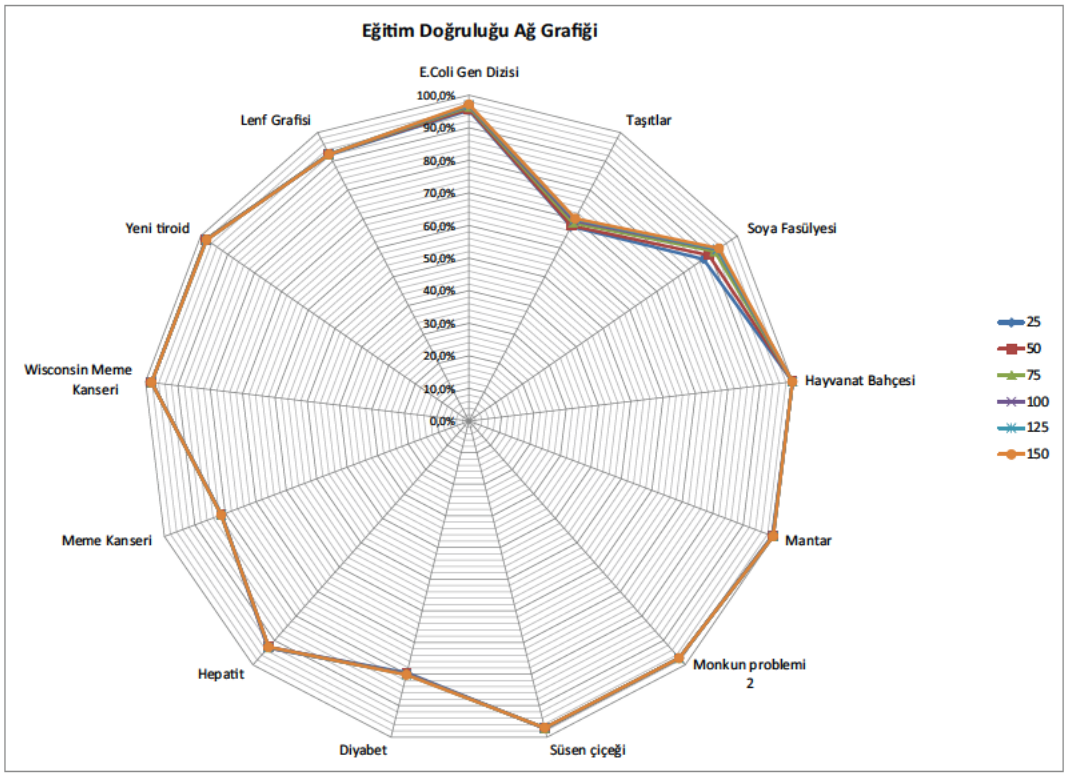
$initOranı$ kontrol parametresi için 5 farklı değer (0,1; 0,25; 0,5; 0,75 ve 1) kullanılarak analiz gerçekleştirilmiştir. Yapılan deneyler sonucu elde edilen ortalama test doğrulukları Tablo 3.26'da, Friedman testi sonuçları Tablo 3.27'de verilmiştir. Şekil 3.24 ve 3.25'te deneylerin ortalama eğitim ve test doğruluklarının radar ağ grafiği gösterilmiştir. Kural ve koşul sayılarındaki değişimler ise Şekil 3.26 ve 3.27'de verilmektedir.



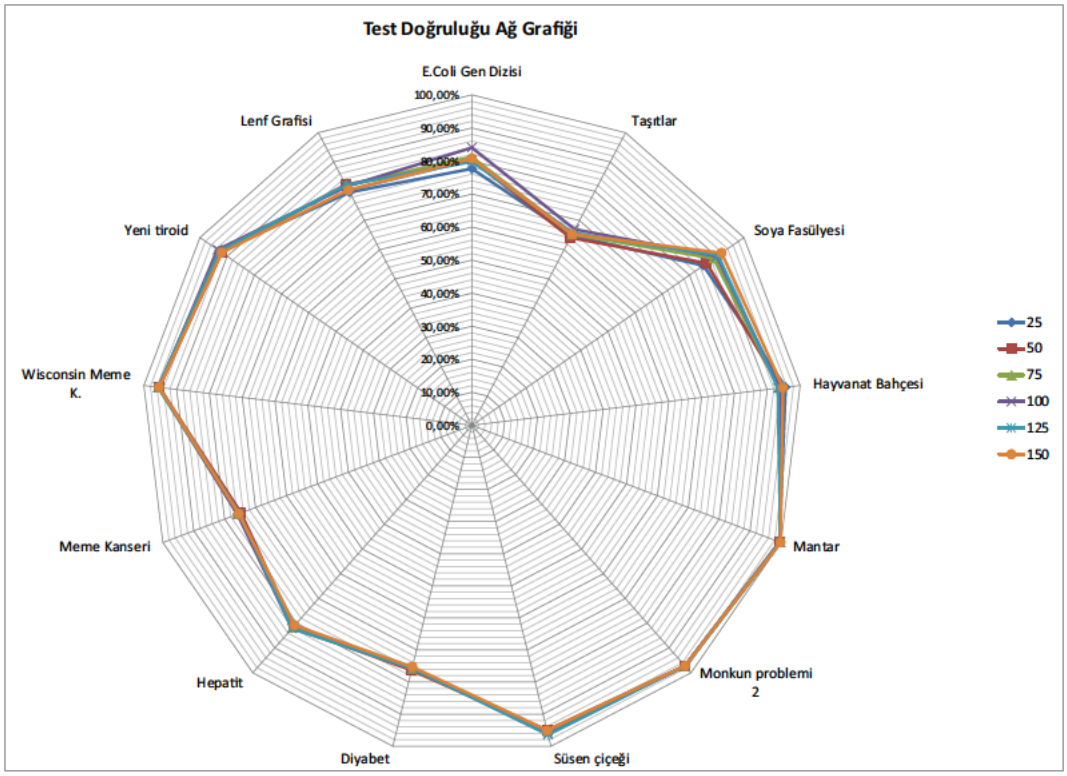
Şekil 3.15. MCN parametre değişimi için kural başına öğrenilen ortalama koşul sayısı grafiği.

Şekil 3.24 incelendiğinde diyabet, hepatit, lenf grafisi, e.coli gen dizisi, taşıtlar ve soya fasülyesi eğitim doğrulukları üzerinde bu parametrenin etkisi açıkca görülmektedir. Şekil 3.25 incelendiğinde ise diyabet, e.coli gen dizisi, taşıtlar ve soya fasülyesi test doğruluklarının $initOranı$ değerinden etkilendiği oldukça açıktır. Test doğrulukları için $initOranı$ parametresi değeri arasında 0,1 değeri en başarılı değerdir (Tablo 3.26).

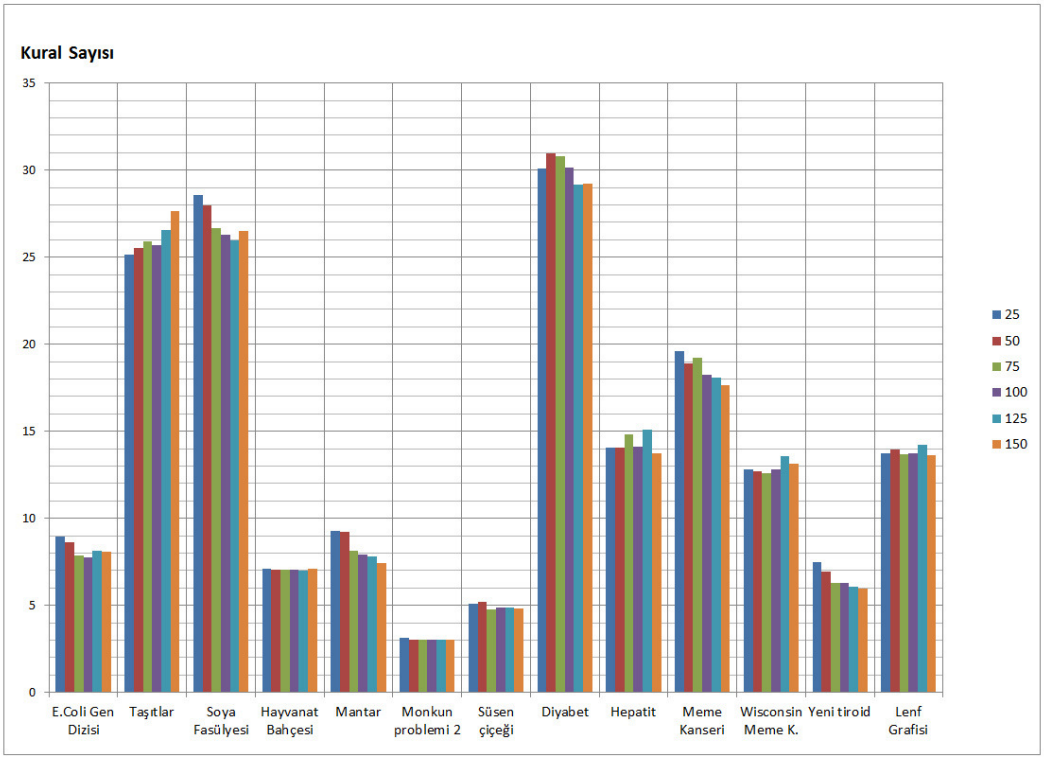
Keşfedilen kural sayılarının $initOranı$ ile aşırı derecede değiştiği gözlenmektedir (Şekil 3.26). Kural başına öğrenilen ortalama koşul sayıları da yine bu parametreyle aşırı derecede değişim göstermiştir (Şekil 3.27). Friedman testi sonuçları analiz edildiğinde $initOranı$ parametresi %5 yanılma düzeyinde diyabet, mantar, e.coli gen dizisi, soya fasülyesi, taşıtlar ve Wisconsin için istatistiksel olarak etkili olmuştur (Tablo 3.27).



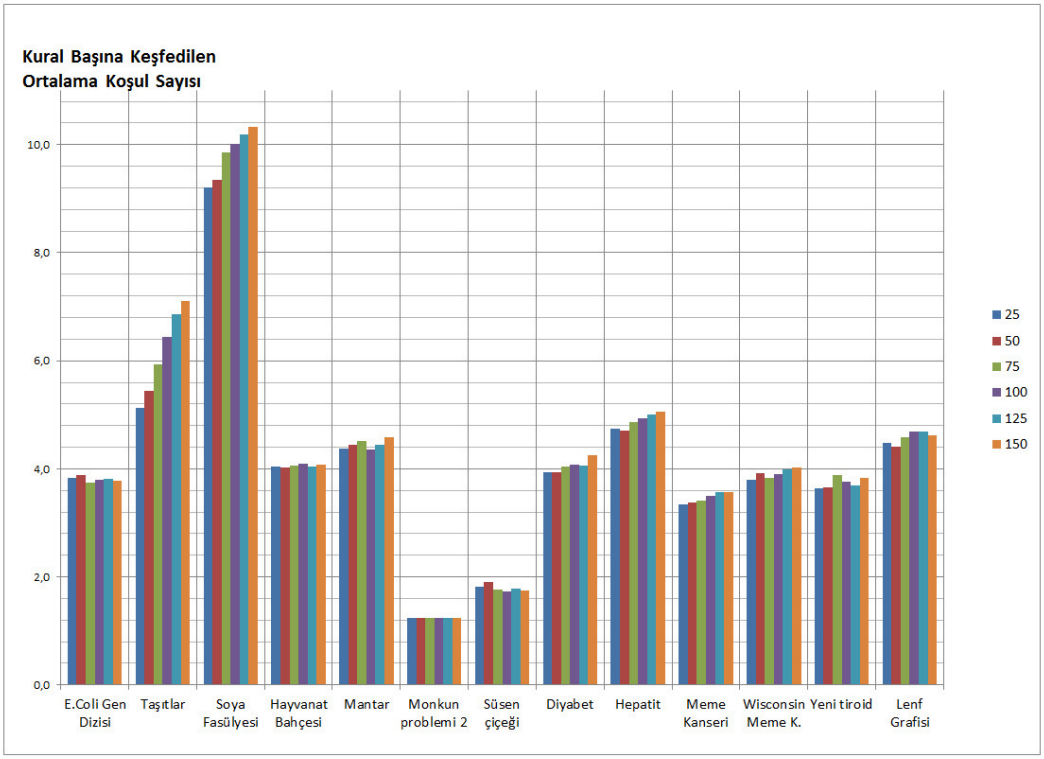
Şekil 3.16. *Limit* parametre değişimi için ortalama eğitim doğruluklarının radar ağ grafiği.



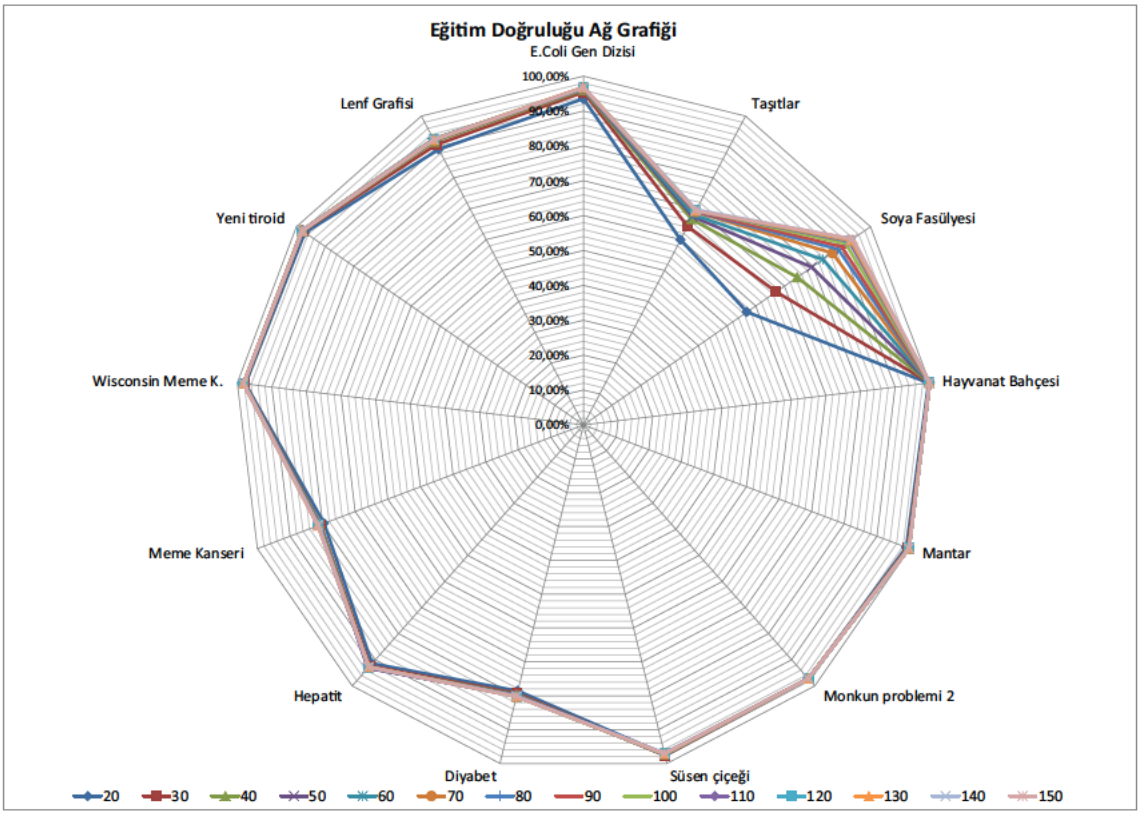
Şekil 3.17. *Limit* parametre değişimi için ortalama test doğruluklarının radar ağ grafiği.



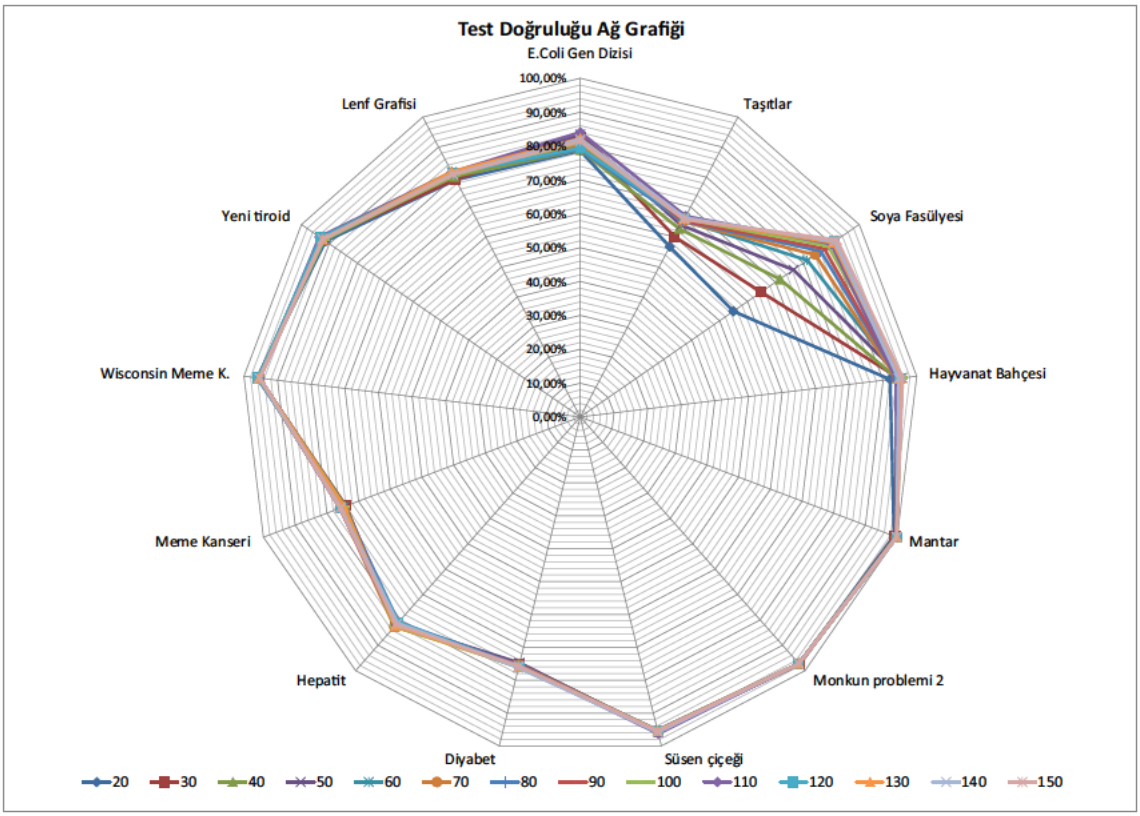
Şekil 3.18. *Limit* parametre değişimi için ortalama kural sayısı grafiği.



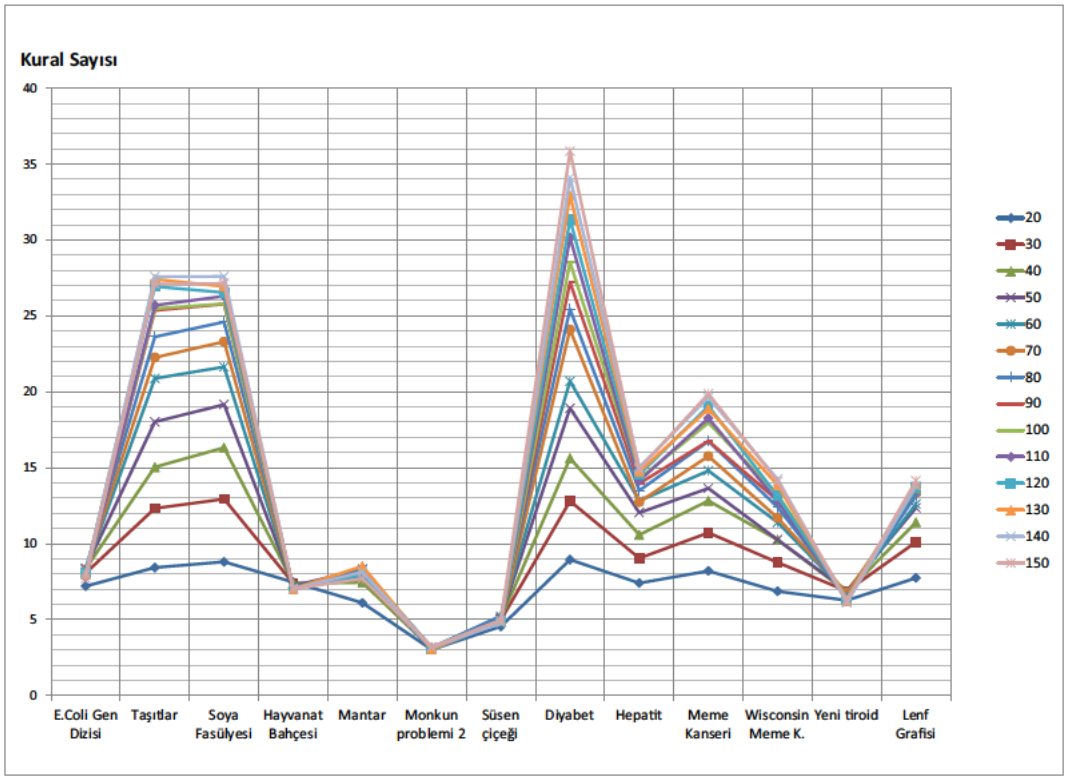
Şekil 3.19. *Limit* parametre değişimi için kural başına öğrenilen ortalama koşul sayısı grafiği.



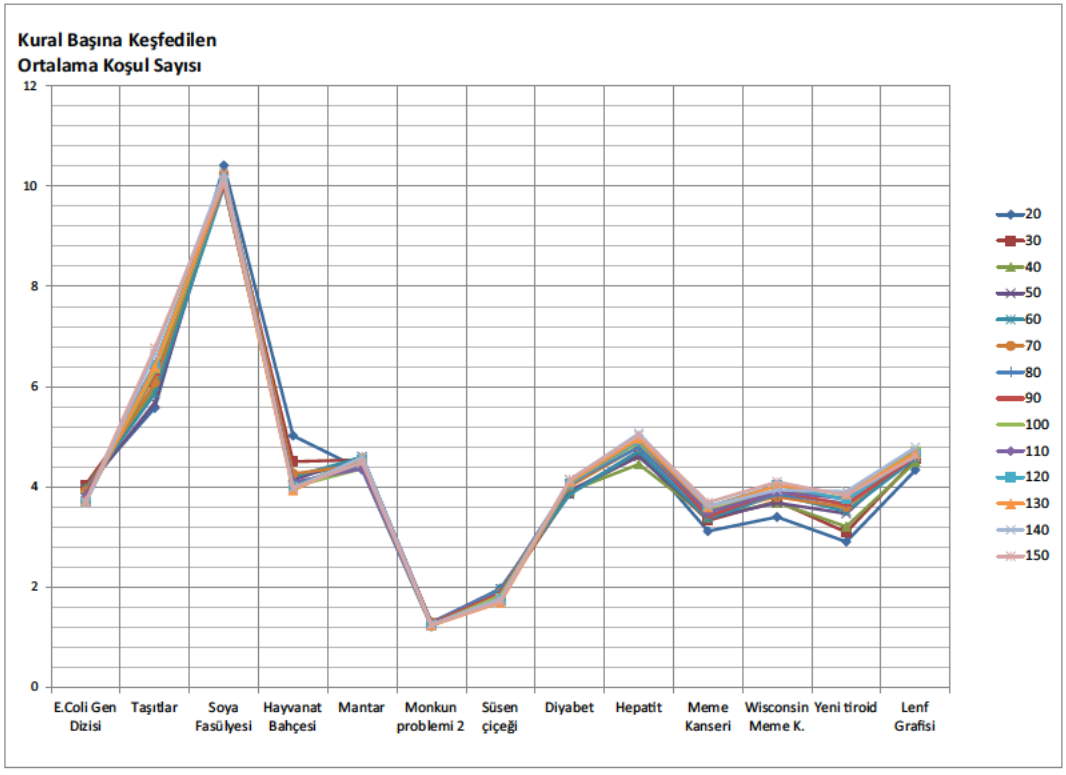
Şekil 3.20. KS parametre değişimi için ortalama eğitim doğruluklarının radar ağ grafiği.



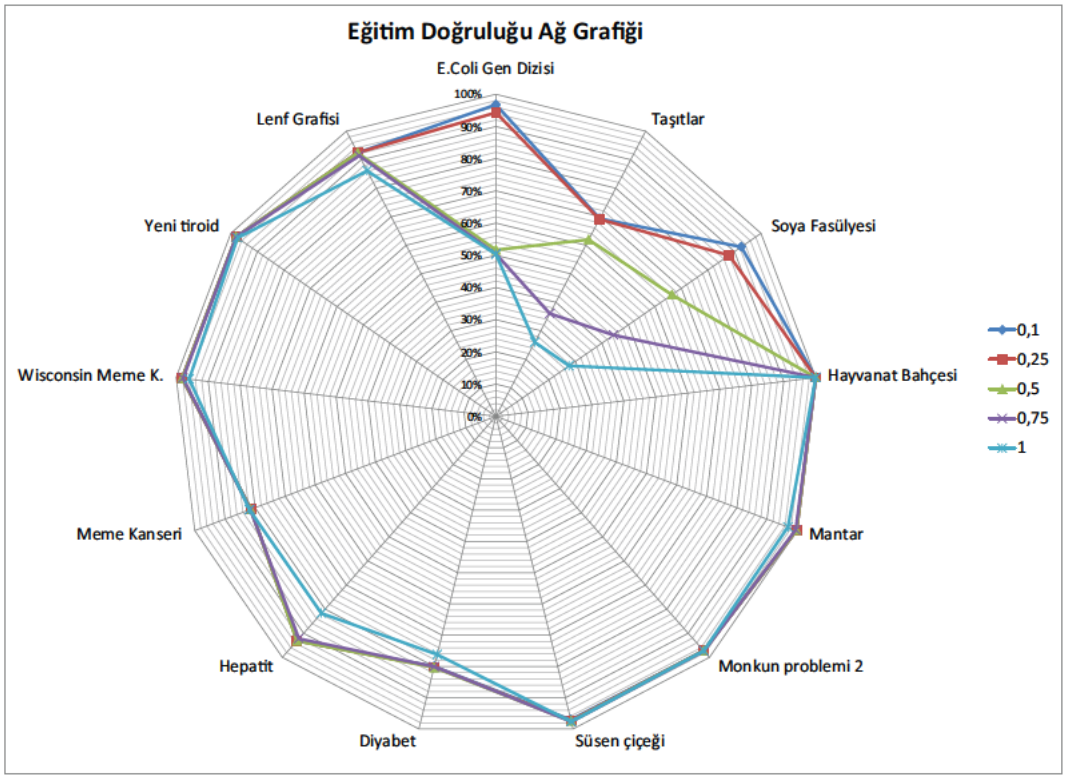
Şekil 3.21. KS parametre değişimi için ortalama test doğruluklarının radar ağ grafiği.



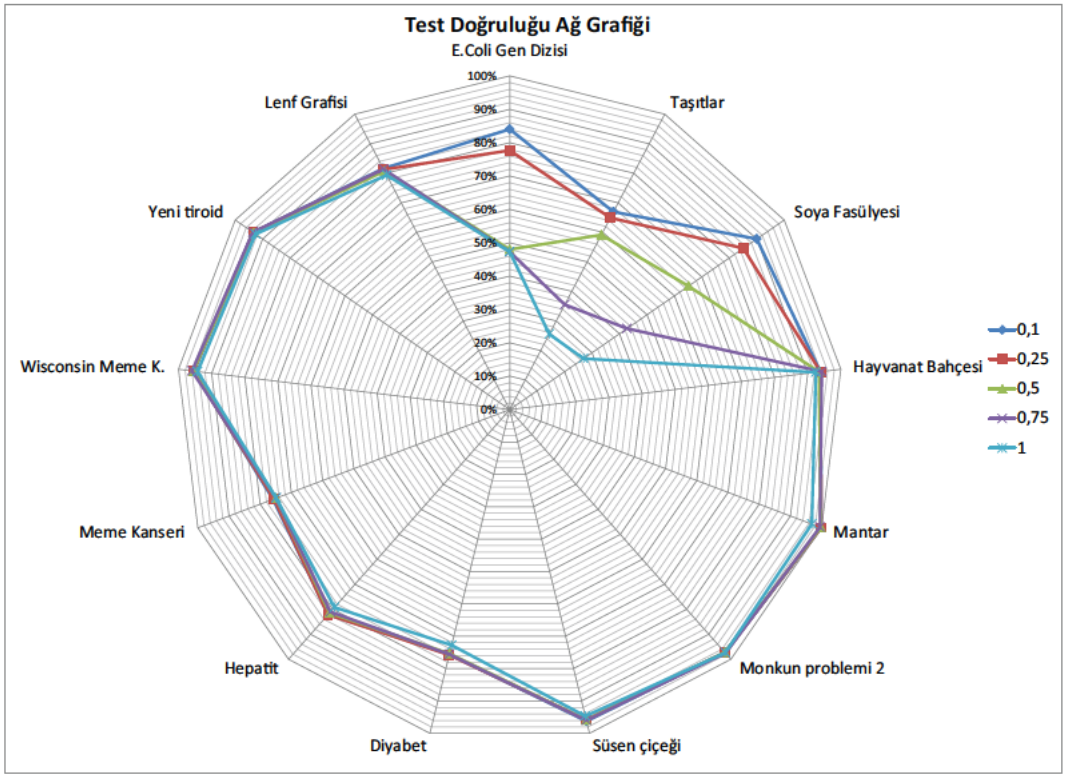
Şekil 3.22. KS parametre değişimi için ortalama kural sayısı grafiği.



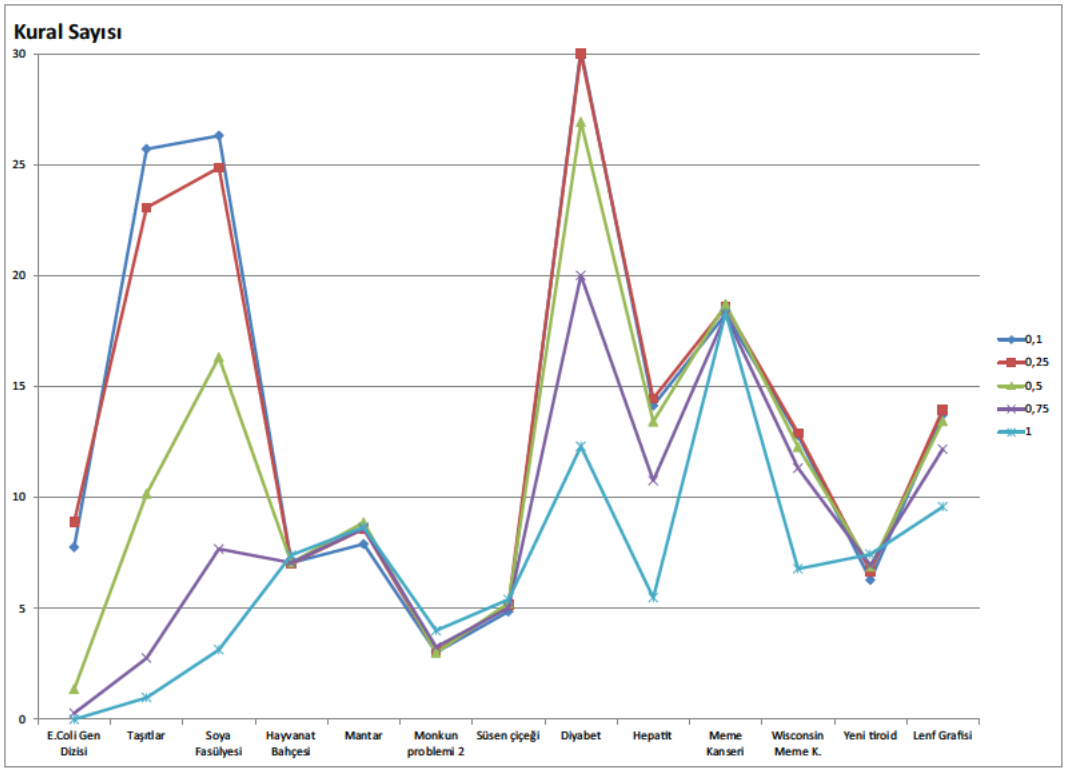
Şekil 3.23. KS parametre değişimi için kural başına öğrenilen ortalama koşul sayısı değişimi grafiği.



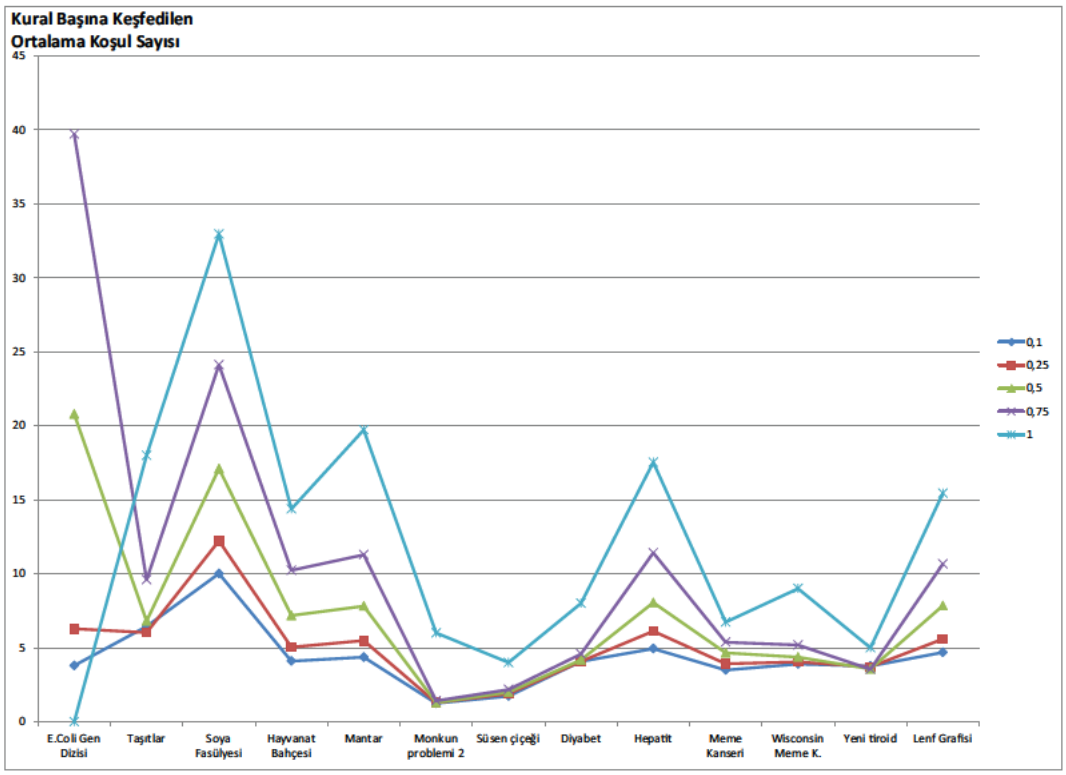
Şekil 3.24. *initOranı* kontrol parametre değişimi için ortalama eğitim doğrulukları radar ağ grafiği.



Şekil 3.25. *initOranı* parametre değişimi için test doğrulukları radar ağ grafiği.



Şekil 3.26. *initOranı* parametre değişimi için ortalama kural sayısı grafiği.



Şekil 3.27. *initOranı* parametre değişimi için kural başına öğrenilen ortalama koşul sayısı grafiği.

Tablo 3.24. KS parametre değişimi ortalama test doğrulukları.

Veri Kümeleri	20	30	40	50	60	70	80
Diyabet	%75,00 (12)	%74,95 (13)	%75,05 (11)	%74,77 (14)	**%76,15 (1)**	%75,31 (10)	%75,60 (8)
Hepatit	%81,71 (9)	%82,34 (4)	%82,60 (2)	%81,63 (10)	%81,60 (11)	**%82,74 (1)**	%80,92 (14)
Süsen Çiçeği	%95,73 (4)	%95,73 (5)	%95,60 (8)	%95,87 (2)	%95,60 (7)	%95,33 (10)	%95,33 (12)
Lenf Grafisi	%79,08 (14)	%79,24 (13)	%80,15 (12)	%80,94 (7)	%81,64 (2)	%81,22 (5)	%81,59 (4)
Monkun Problemi 2	%97,31 (2)	**%97,45 (1)**	%97,22 (14)	%97,27 (6,5)	%97,27 (6,5)	%97,27 (6,5)	%97,27 (6,5)
Mantar	%99,00 (14)	%99,35 (13)	%99,58 (12)	%99,68 (11)	%99,69 (10)	%99,77 (9)	%99,80 (8)
Yeni Tiroid	%91,32 (14)	%92,29 (12)	%92,87 (5)	%92,58 (6)	%92,87 (4)	%92,50 (7)	%92,97 (3)
E.Coli Gen Dizisi	%78,56 (14)	%82,58 (3)	%78,91 (13)	%83,33 (2)	%80,36 (9)	%80,02 (10)	%78,96 (12)
Soya Fasülyesi	%54,91 (14)	%64,89 (13)	%71,60 (12)	%76,46 (11)	%81,38 (10)	%84,27 (9)	%86,18 (8)
Taşıtlar	%56,77 (14)	%60,03 (13)	%62,77 (12)	%63,97 (11)	%65,51 (7)	%65,18 (10)	%65,32 (9)
Wisconsin Meme K.	**%96,08 (1)**	%95,56 (6)	%95,56 (5)	%95,34 (13)	%95,82 (2)	%95,54 (7)	%95,51 (9)
Kanser	%74,24 (12)	%73,97 (14)	%74,20 (13)	%75,83 (3)	%74,48 (10)	%75,78 (4)	%74,54 (8)
Hayvanat Bahçesi	%92,07 (14)	%94,82 (7)	%94,22 (11)	%95,62 (2)	%95,24 (4)	%94,04 (12)	%94,40 (10)
Ortalama	%82,45 (14)	%84,09 (13)	%84,64 (12)	%85,64 (11)	%85,97 (10)	%86,07 (8)	%86,03 (9)
Veri Kümeleri	90	100	110	120	130	140	150
Diyabet	%75,75 (6)	%75,91 (4)	%75,57 (9)	%75,88 (5)	%75,93 (3)	%76,14 (2)	%75,65 (7)
Hepatit	%81,89 (8)	%82,57 (3)	%82,06 (6)	%81,07 (13)	%82,33 (5)	%81,32 (12)	%81,93 (7)
Süsen Çiçeği	%95,20 (13)	%95,60 (6)	**%96,27 (1)**	%95,20 (14)	%95,33 (11)	%95,87 (3)	%95,47 (9)
Lenf Grafisi	%80,78 (10)	%80,58 (11)	%81,60 (3)	%81,21 (6)	**%81,76 (1)**	%80,93 (8)	%80,83 (9)
Monkun Problemi 2	%97,27 (11,5)	%97,27 (11,5)	%97,27 (6,5)	%97,27 (6,5)	%97,27 (13)	%97,27 (6,5)	%97,27 (6,5)
Mantar	%99,81 (7)	%99,83 (4)	**%99,86 (1)**	%99,82 (6)	%99,86 (2,5)	%99,86 (2,5)	%99,82 (5)
Yeni Tiroid	%92,48 (8)	%91,92 (13)	**%93,51 (1)**	%93,13 (2)	%92,35 (11)	%92,48 (9)	%92,40 (10)
E.Coli Gen Dizisi	%82,04 (5)	%81,09 (8)	**%84,02 (1)**	%79,33 (11)	%82,18 (4)	%82,00 (6)	%81,36 (7)
Soya Fasülyesi	%87,47 (7)	%88,84 (6)	%89,98 (5)	%91,27 (2)	%90,60 (4)	%91,27 (3)	**%92,03 (1)**
Taşıtlar	%65,44 (8)	%66,08 (4)	**%66,93 (1)**	%66,06 (5)	%66,11 (3)	%66,41 (2)	%65,84 (6)
Wisconsin Meme K.	%95,42 (10)	%95,59 (4)	%95,34 (12)	%95,68 (3)	%95,51 (8)	%95,37 (11)	%95,22 (14)
Kanser	%74,49 (9)	%74,47 (11)	**%75,86 (1)**	%75,56 (6)	%74,63 (7)	%75,58 (5)	%75,86 (2)
Hayvanat Bahçesi	%94,40 (9)	%95,60 (3)	%93,82 (13)	%95,00 (6)	%95,02 (5)	%94,62 (8)	**%95,82 (1)**
Ortalama	%86,34 (7)	%86,57 (6)	**%87,08 (1)**	%86,65 (5)	%86,84 (4)	%86,85 (3)	%86,88 (2)

Tablo 3.25. KS parametre değerlerinin test doğrulukları için Friedman testi.

Veri Kümeleri	sd	χ^2	p değeri
Diyabet	13	18,368	0,14404
Hepatit	13	6,157714	0,940224
Süsen Çiçeği	13	3,036	0,997801
Lenf Grafisi	13	4,815429	0,979035
Monkun Problemi 2	13	0,164	1
Mantar	13	185,224571	**0**
Newthyroid	13	5,965714	0,947392
E.Coli Gen Dizisi	13	13,273714	0,426899
Soya Fasülyesi	13	530,505143	**0**
Taşıtlar	13	166,595429	**0**
Wisconsin Meme K.	13	12,589143	0,480024
Kanser	13	22,257143	0,051503
Hayvanat Bahçesi	13	11,847429	0,540193

Tablo 3.26. $initOranı$ parametre deneyleri ortalama test doğrulukları.

Veri Kümeleri	0,1	0,25	0,5	0,75	1
Diyabet	%75,57 (3)	**%75,75 (1)**	%75,39 (4)	%75,60 (2)	%72,76 (5)
Hepatit	%82,06 (2)	**%82,16 (1)**	%81,45 (3)	%81,03 (4)	%79,22 (5)
Süsen Çiçeği	**%96,27 (1)**	%95,73 (4)	%95,87 (3)	%96,00 (2)	%94,67 (5)
Lenf Grafisi	**%81,60 (1)**	%81,24 (3)	%80,72 (4)	%81,39 (2)	%79,36 (5)
Monkun Problemi 2	%97,27 (4)	%97,27 (4)	%97,27 (4)	**%97,54 (1)**	%97,40 (2)
Mantar	**%99,86 (1)**	%99,83 (2)	%99,75 (3)	%99,47 (4)	%96,87 (5)
Yeni Tiroid	%93,51 (2)	%93,44 (3)	%93,25 (4)	**%93,53 (1)**	%92,57 (5)
E.Coli Gen Dizisi	**%84,02 (1)**	%77,65 (2)	%48,00 (3)	%47,27 (4,5)	%47,27 (4,5)
Soya Fasülyesi	**%89,98 (1)**	%85,10 (2)	%65,13 (3)	%42,74 (4)	%26,89 (5)
Taşıtlar	**%66,93 (1)**	%64,87 (2)	%59,11 (3)	%35,52 (4)	%25,55 (5)
Wisconsin Meme K.	%95,34 (4)	%95,51 (3)	%95,57 (2)	**%95,94 (1)**	%94,27 (5)
Kanser	**%75,86 (1)**	%75,56 (2)	%74,92 (3)	%74,91 (4)	%74,85 (5)
Hayvanat Bahçesi	%93,82 (3)	%93,85 (2)	%93,44 (4)	**%94,22 (1)**	%92,45 (5)
Ortalama	**%87,08 (1)**	%86,00 (2)	%81,53 (3)	%78,09 (4)	%74,93 (5)

Tablo 3.27. $initOranı$ parametre değişimi test doğrulukları için Friedman testi.

Veri Kümeleri	sd	χ^2	p değeri
Diyabet	4	17,368	**0,001639**
Hepatit	4	3,992	0,40709
Süsen Çiçeği	4	3,308	0,507666
Lenf Grafisi	4	1,812	0,770286
Monkun Problemi 2	4	0,34	0,987088
Mantar	4	116,596	**0**
Newthyroid	4	1,52	0,823093
E.Coli Gen Dizisi	4	142,288	**0**
Soya Fasülyesi	4	192,176	**0**
Taşıtlar	4	171,088	**0**
Wisconsin Meme K.	4	15,864	**0,003207**
Kanser	4	3,804	0,433181
Hayvanat Bahçesi	4	1,488	0,828765

3.2.4. Değerlendirme

Bu bölümde kural tabanlı sınıflandırma modellerinin öğrenimi için yeni geliştirilen ABC'ye dayalı birleşik kural öğrenme algoritması (CoABCMiner) açıklanmıştır. Algoritmanın değerlendirilmesi amacıyla 13 farklı test problemi üzerinde elde ettiği sonuçlar ABCMiner, C4.5, LDWPSO, CORE, SIA, PGIRLA ve HIDER algoritmaları ile karşılaştırılmıştır. Test problemleri üzerinde yapılan deneylerde CoABCMiner'ın diğer algoritmalara göre daha yüksek doğruluğa sahip sınıflandırma modelleri öğrendiği görülmüştür. Tablo 3.14'de verilen eğitim doğruluğu, eğitim doğrulukları standart sapma değeri, test doğruluğu, test doğrulukları standart sapma değeri, kural sayısı, koşul sayısı, çalışma süresi ölçütleri incelendiğinde genel ortalamada 1. olmuştur.

Algoritma 33 dengesiz sınıf dağılımlı test problemi üzerinde çalıştırılmıştır. Sonuçlar ABCMiner, COGIN, CORE, DMEL, DT-GA, Gassist, GIL, HIDER, ILGA, ObliqueDT, OCEC, OIGA, PGIRLA, SIA, Target, UCS ve XCS algoritmaları ile karşılaştırılmıştır. Algoritmalar problemler için elde edilen ortalama test doğruluğu sonuçları (Tablo 3.17 ve 3.18) kullanılarak sıralandığında elde edilen 3,61 sıra ortalamasıyla CoABCMiner algoritması birinci sırada yer almıştır. CoABCMiner algoritması kuralları bir arada öğrendiği için geliştirilen sınıflandırma modeli hem az sayıda kural içermiş hem de yüksek test başarı oranlarına sahip olmuştur.

CoABCMiner'ın geliştirdiği sınıflandırma modelinin ne doğru sınıflandıramayacak kadar az sayıda kural ne de aşırı öğrenme yaparak gereksiz karmaşıklığa sahip olacak kadar çok sayıda kural içermediği ve makul sayıda kurala sahip olduğu yapılan deneylerde görülmüştür.

4. BÖLÜM

ONLINE-ABCMINER: ADAPTİF ÇEVRİM-İÇİ KURAL ÖĞRENME ALGORİTMASI

Bu bölümde açık uçlu veri akışı üzerinden sınıflandırma modeli öğreniminde kullanabilmek amacıyla geliştirilen ABC'ye dayalı adaptif çevrim-içi kural öğrenme algoritması olan Online-ABCMiner açıklanmaktadır.

Sınıflandırma problemlerini çözmek için geliştirilmiş çevrim-dışı çalışan klasik algoritmalar; sınırlı sayıda örnekten oluşmuş veri kümesini kullanarak yaptığı eğitim ile en uygun sonucu veren durağan bir sınıflandırma modeli geliştirmektedir. Nesnelerin interneti (IoT), genetik ya da astronomik bilimsel veri toplamalar, sosyal ağ trafiği, para ve hisse senedi piyasası ve perakende satışlardaki müşteri eğilimleri gibi uygulama alanlarında elde edilen sürekli ve değişken özellikteki kesintisiz veri akışı büyük kapasitede veri işleme ihtiyacını ortaya çıkarmıştır. Veri akışının adeta bir nehir gibi hızlı ve kesintisiz oluşu buna karşın mevcut çevrim-dışı algoritmaların analiz için yetersiz kalması nedeniyle, akan verinin toplama ve iletimi esnasında eş-zamanlı biçimde işlenmesi için yeni çevrim-içi algoritmalara ihtiyaç duyulmaktadır [83–87].

Veri akışı (data stream) kavramı, sürekli, açık uçlu ve yüksek hacimli olma özelliklerine sahiptir [88] ve veri akışı sabit ve değişken karakteristikli olmak üzere iki gruba ayrılır. Fiziksel çevrede bir değişikliğin olmadığı durumlarda, verinin tek bir örneklem dağılımı kaynağından alınması sabit veri akışı oluşturur. Hem süre hem de kullanılırlık bakımından eğitim veri kümesi için örneklerin bir araya getirilemediği problemler sabit veri akışına dahildir. Çevrim-içi algoritma her an bir sınıflandırma modeline sahip olduğu için hem sınıflandırma tahmininde kullanılır, hem de yeni veriler geldikçe modeli daha kullanışlı yapmak için eğitmektedir. Hastalık teşhisi için kullanılacak bir çevrim-içi sistemde toplanan veriler bu tür sabit veri akışına örnek olarak verilebilir. Çevrim-içi sistem daha

önceden elde edilen veriler ile eğittiği sınıflandırma modelini bir yandan kullanırken bir yandan da hasta verileri toplandıkça da daha doğru sonuç verecek biçimde bu modeli iyileştirir. İkinci grup veri akışı değişken karakteristiğe sahip veri akışıdır. Bu türdeki bir sisteme gelen veri, fiziksel çevrede ortaya çıkan değişiklikler nedeniyle birbirinden farklı örneklem dağılımı kaynaklarından gelmekte ve dolayısıyla sınıflandırma modelinin zamana bağlı olarak değişikliğe uğraması gerekmektedir. Veri akışında meydana gelen bu değişiklikler kavram sapması (concept drift) olarak adlandırılmaktadır. Gürültü ile kavram sapması birbiriyle kolaylıkla karıştırılabilen ve veri akışı üzerinden sınıflandırma modellerinin doğruluğunu etkileyen en temel problemlerdir. Gürültü, veride olmaması gereken ve ölçüm sırasında ortaya çıkan istenmeyen değişikliklerdir. Modellerin gürültüye karşı kararlı davranması istenir ve fiziksel çevrede ortaya çıkan değişiklikleri ifade eden kavram sapması karşısında model uyarlanabilmelidir. Kavram sapması literatürde ani ve kademeli olmak üzere iki gruba ayrılmıştır. Verilerin farklı dağılımlar üzerinden alınmasının zamanlaması farklılıklara yol açmaktadır. Hızlı biçimde ikinci örneklem dağılımından veriler okunmaya başlanması ve önceki örneklem dağılımından veri alımının kesilmesi ani kavram sapması olarak adlandırılır. Veri akışından gelen örnekler içinde önceki örneklem dağılımının etkinliğini sürdürmesi yanında yeni örneklem dağılımınından alınan veri oranının gittikçe artmasına kademeli kavram sapması denilmektedir. Ağ saldırısı tespiti, kredi kartı sahteciliği önleme sistemi ve insan davranışına dayalı diğer uygulamaların modellenmesi sırasında giriş üzerinde bu tür değişiklikler görülmektedir. Değişken veri akışına bir örnek olarak perakende teknoloji mağazasında gerçekleşen satışlar verilebilir. Teknolojik cihazlardaki ürün çeşitliliği ve müşteri eğilimleri sürekli değişmektedir. Güncel satış verilerinin incelenmesi sonucu belirlenen bir değişime bağlı olarak pazarlama ve satış stratejileri güncellenip yeni kampanyalar geliştirilebilir. Veri akışı kaynağı değiştikçe giriş öznitelikleri ile çıkış sınıfı arasındaki daha önceden öğrenilen modelin doğruluğu kaybolacak veya azalacaktır. Bir değişim sezildiğinde zaman kaybetmeden en hızlı biçimde çevrim-içi algoritmayı kullanarak sınıflandırma modeli üzerinde gerekli değişikliğin yapılması gerekecektir. Kademeli veya köklü iyileştirme stratejileri ile probleme özgü farklı çevrim-içi öğrenme yaklaşımları ortaya konulmuş ve değişime uyum gösterilmeye çalışılmıştır [88–91].

Veri akışı için ideal bir çevrim-içi öğrenme sistemi aşağıda açıklanan 6 tasarım kriterini

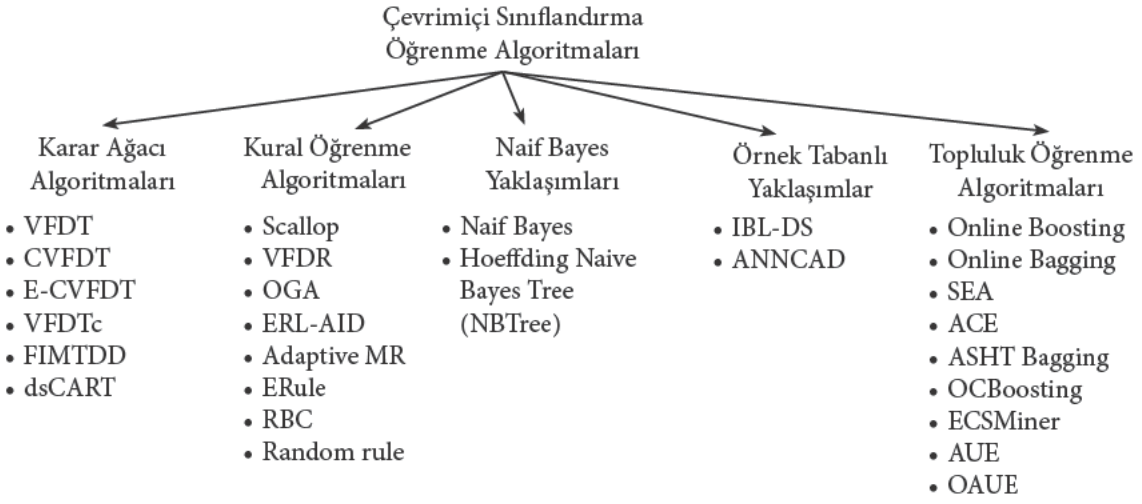
karşılamalıdır [88]:

- Sınırlı işlem süresi: Çok hızlı veri akışı olduğu için yeni gelen her verinin işlenmesi sabit bir süre içinde tamamlanmalıdır. Bir işlemin bu süre içerisinde bitirilememesi halinde sonraki gelecek verinin işlenmesi aksayacaktır.
- Sabit bellek kullanımı: Veri akışının açık uçlu olması nedeniyle sürekli yeni bilgi gelmekte ve dolayısıyla sınırlı bellek kapasitesi içinde verilerin hepsinin kayıtlı tutulması mümkün olmamaktadır. Bu yüzden çevrim-içi algoritma önceden belirlenmiş sınırlı ve sabit bellek kapasitesi içinde çalışabilmelidir.
- Bir kez işlenme zorunluluğu: Bellek kapasitesi ve işlem hızı sınırları içinde kalmak kaydıyla örnekler tekrar işleme ihtiyacı duymadan sadece bir kez analiz edilmelidir.
- Anlık kullanışlı model: Çevrim-içi yaklaşım her an tahmin işleminde kullanılmak üzere kullanışlı bir sınıflandırma modeli sunabilmelidir. Klasik yöntemler, öğrenme süreci tamamlanıncaya kadar bir sınıflandırma modeli verememesinden dolayı tahmin için kullanılamaz.
- Denk bir son model: Bütün veriler toplandığında ortaya çıkan eğitim kümesi çevrim-dışı yaklaşımla öğrenildiğinde elde edilecek modelin kalitesine denk bir kalitede model çevrim-içi sistem tarafından da öğrenilebilmelidir.
- Adaptasyon yeteneği: Veri akışı dinamik yapıdadır ve sistem davranışına göre değişme olasılığı içerir. Veri akışı değişiminin ne zaman başlayacağı ve nasıl bir karakteristiğe sahip olduğu öngörülemeyeceği için muhtemel bir kavram sapması karşısında çevrim-içi algoritma değişimi hızlı biçimde sezebilmeli ve modeli gözden geçirip yeniden düzenleyerek her an için kararlı ve güncel bir model ortaya koyabilmelidir.

Şekil 4.1'de çevrim-içi veri akışı sınıflandırma algoritmaları verilmiştir. Çevrim-içi sınıflandırma yaklaşımları karar ağaçları, kural öğrenme, naif Bayes yöntemler, örnek karşılaştırma ve topluluk yöntemleri olmak üzere 5 gruba ayrılmaktadır. Birinci grupta yer alan algoritmalar karar ağacı öğrenme algoritmalarıdır. Eğitim örnekleri arasında ortak öznitelikleri araştırarak genelleştirme ve indirgeme yapmaktadır. Karar ağacı ile ilk geliştirilen çevrim-içi sınıflandırma algoritması VFDT algoritmasıdır [86]. VFDT

algoritmasında karar ağacı düğüm noktalarının belirlenmesi için Hoeffding olasılık sınırı kullanılmıştır. Hoeffding eşitsizliğinde rastgele değişkenin gerçek ortalaması ile az sayıda örnekle bulunan ortalama değeri farkının belirli güven aralığı içinde sınırlandırılması için gerekli en az örnek sayısı tahmin edilmektedir. Dolayısıyla VFDT karar ağacı üzerinde en iyi ayrıştırmayı sağlayacak yeni bir dal düğümü ekleyebilmek için gerekli olan minimum örnek sayısını, Hoeffding sınırı ile tahmin etmektedir. Böylece algoritma eldeki minimum sayıdaki veriyle belirlenecek dallanma kararının en iyi dallanma çözümü ile olacak hata farkının güven aralığı içinde belirli bir sınır değer altında kalmasını istatistik açıdan garanti etmektedir. Fazla sayıda veri hafızada tutulmadan karar ağacına yeni dallar eklenir ve sınıflandırma modeli geliştirilir. VFDT algoritması her bir karar düğümü için yeterli sayıda istatistik verileri saklar. Yeni bir örnek geldiğinde karar ağaç üzerinde test edilir, örnek ile örtüşen yaprak düğümün istatistik değerleri güncellenir. İlgili yaprak düğümü yeterli sayıda örnek geldiğinde en yüksek maliyete sahip öznitelik ile bir sonraki özniteliğin istatistik değeri karşılaştırılır. Bu fark Hoeffding sınırından yüksek olursa ilk öznitelik yeni karar noktası olarak atanarak ağaç genişletilir. Hoeffding şartı sağlanmadığında saklanan veri miktarının çok fazla sayıya ulaşması algoritmanın dezavantajıdır [86]. VFDT algoritmasını temel alan başka karar ağacı yaklaşımları da geliştirilmiştir. VFDTc adı verilen diğer bir algoritma karar düğümlerinde naif Bayes yaklaşımları kullandığından dolayı sayısal özniteliğe sahip verileri de sınıflandırabilmektedir [92]. VFDT algoritmasına dayalı başka bir yöntem ise CVFDT algoritmasıdır ve değişken karakteristiğe sahip veri akışlarına uyum sağlayacak eklentiler ile geliştirilmeye çalışılmıştır. Kavram sapması tespit edilirse ana karar ağacı üzerindeki dallar farklı yeni alt ağaçlar ile değiştirilir [85]. FIMT-DD algoritması değişken veri akışı için gelen en son örneklerden oluşan pencere ile eldeki mevcut karar ağacının dallarını analiz ederek gerekirse değiştiren bir regresyon ağacı öğrenme algoritmasıdır [90]. dsCART algoritması, VFDT algoritmasındaki Hoeffding sınırı yerine klasik CART algoritmasının Gini kazancı hesabını kullanarak geliştirilmiştir [93, 94].

Kural tabanlı sınıflandırma sistemleri, sınıflandırma modelini "Eğer-İse" kuralları ile öğrenmektedir. Örnekler arası ortak özellikler belirlenip kural biçiminde ortaya konulmaktadır. Böylece arama uzayının görüldüğü kısmı için çevrim-içi algoritma tarafından kural kümesi çıkartılır. Arama uzayının örnek alınamamış karanlık bölgeleri



Şekil 4.1. Çevrim-içi sınıflandırma öğrenme algoritmaları.

hakkında sistemin bir sınıf tahmini yoktur. VFDR algoritması veri akışı için geliştirilmiş VFDT karar ağacı algoritmasını temel alan bir kural öğrenme algoritmasıdır. Bu algoritma karar için VFDTc algoritmasında olduğu gibi Naif Bayes teoremini kullanan kurallar öğrenmektedir [95]. SCALLOP çevrim-içi sınıflandırma için geliştirilmiş başka bir kural öğrenme algoritmasıdır. Sadece sayısal özniteliği olan veri akışı öğrenebilmektedir. Gürültünün yanlışlıkla kavram sapması kabul edilerek güncelleme yapılmasını önlemek için SCALLOP algoritması yazarları tarafından FACIL algoritması adıyla yeni bir çevrim-içi kural tabanlı sınıflandırma algoritması geliştirilmiştir. SCALLOP ve FACIL, veri akışında gelen her yeni örneği daha önce öğrendiği kurallar ile karşılaştırır ve örneği birebir karşılayan bir kural sınıflandırma modelinde bulunamadığında kurallar ile olan yakınlığı ölçülerek sınıf tahmini yapılır [96, 97]. RBC, topluluk modeli biçiminde geliştirilmiş kural tabanlı öğrenme algoritmasıdır. Her bir bileşen diğerinden bağımsız biçimde sınıflandırma modeline gerektikçe eklenir ya da güncellenir. Parçacıklı yapıdan oluşan bir sınıflandırma modeli üzerine kurulduğu için RBC algoritmasının hem değişimlere karşı adaptasyon yeteneğinin daha yüksek olduğu hem de güncelleme maliyetlerinin diğer karar ağacı ve topluluk algoritmalarına göre düşük olduğu ifade edilmiştir [98]. Başka bir kural öğrenme algoritması olan eRules, PRISM klasik kural öğrenme algoritmasını temel almış ve kayan pencere yaklaşımı ile veri akışına uyarlanmıştır [99]. Adaptive MRUles, kural temsili ile regresyon problemlerini modellemek amacıyla geliştirilmiş veri akışı öğrenme algoritmasıdır [100].

Veri akışı sınıflandırma modeli öğrenimi için meta-sezgisel algoritmaya dayalı

yaklaşımlar da geliştirilmiştir [101–103]. Sezgisel algoritmalar tekrarlı uygunluk hesaplaması yapmak ve çözümleri iyileştirme ihtiyacından dolayı veri akışı için tam anlamıyla uygulanabilir değildir. Bunun için sezgisel algoritmaların tekrarlı iyileştirme gereksinimini ortadan kaldıran değişiklikler yapılarak veri akışı öğreniminde kullanılmıştır. OGA, veri akışı için Genetik Algoritma temelli, birbirinden bağımsız biçimde farklı sınıflar için eş-zamanlı kural öğrenen bir çevrim-içi kural öğrenme algoritmasıdır [102]. ERL-AID, sabit Genetik Algoritma (steady state GA) kullanılarak geliştirilmiş her yeni adımda popülasyondaki sadece bir bireyi yenisi ile değiştiren bir çevrim-içi öğrenme algoritmasıdır. ERL-AID algoritması çözüm popülasyonundaki her bir çözüm bir kuralı temsil etmektedir. Algoritma belirli sayıda veri topladıktan sonra kuralları toplu biçimde öğrenir ve daha sonra kayan pencere yaklaşımı ile modeli geliştirmeye çalışır. Her yeni örnek geldiğinde öncelikle model tarafından sınıflandırmaya çalışılır ve örnek karşılanmadığında yeni bir kural geliştirilir [103].

Naif Bayes sınıflandırıcılar, örneklemeler üzerinden yapılan önermeyle ifade edilen olasılık temelli bir sınıflandırma yaklaşımıdır. Geçerli bir tahmin yapılabilmesi için gerekli şart özniteliklerin birbirinden istatistik bağımsız olmasıdır. Sınıflandırmanın yüksek doğrulukla yapılabilmesi için istatistik değerler yeterli sayıda örnekle hesaplanmalıdır [34,104]. Çevrim-içi kullanılabilmesi için veri akışında yeni verinin sınıf tahmini yapılırken bir yandan da Bayes sınıflandırıcının parametrelerinin güncellenmesi gerekir. Her bir öznitelik için geçerli artımlı ortalamayla standart sapma değerleri ve toplam örnek sayısı saklanmalıdır. Çevrim-içi Bayes sınıflandırıcıların en büyük dezavantajı muhtemel bir sapma durumunda sınıflandırıcının güncellenmesinin mümkün olmamasıdır. Veri akışı üzerinde ortaya çıkan bir kavram sapması Bayes sınıflandırıcının önceki istatistik değerlerini geçersiz kılacaktır. Bundan dolayı kavram sapması algılama yöntemleri geliştirilmiş herhangi bir sapma algılanınca sınıflandırıcı istatistikleri baştan yenilenmiş ve hatalı sınıflandırmanın önüne geçilmeye çalışılmıştır. Kavram sapmasının hızlı biçimde sezilmesi hatalı sınıflandırmaların önüne geçer. Ani bir değişim ortaya çıktığında yeni bir model öğrenilir. Veride yer alan gürültünün kavram sapmasından ayırt edilmesi ve modelin etkilenmemesi gereklidir [105–107]. NBTree çevrim-içi sınıflandırma algoritması, naif Bayes yaklaşımı ile Hoeffding karar ağacını birleştirerek geliştirilmiş bir yaklaşımdır. Özniteliklere bağlı dallanma işlemleri

Hoeffding olasılık değeri ile belirlenmiş son yaprakta yer alan her bir düğümde ise naif Bayes sınıflandırıcılar kullanılmıştır [108–110].

Örnek tabanlı algoritmalar, problemi özetleyici bir model geliştirmeyip, yeni durumu bellekteki bilinen örnekler ile karşılaştırarak sınıflandırma yapan sınıflandırma algoritmalarıdır. Örnek tabanlı yaklaşımların çevrim-içi sınıflandırmasında kullanılması için literatürde çeşitli çalışmalar yapılmıştır. Sınıf kararı verilebilmesi için karşılaşılan örneklerin tamamının bellekte saklanma gerekliliği ve karşılaştırmada kullanılması örnek tabanlı yöntemlerin çevrim-içi sınıflandırmadaki en büyük dezavantajıdır [87, 111–113]. IBL-DS yaklaşımı, konumsal yakınlık, tutarlılık ve veri güncelliği kriterlerini birleştirmiş ve örnek tabanlı k-en yakın komşuluk algoritmasını veri akışı sınıflandırma problemine uyarlamıştır. IBL-DS'de her yeni örnek geldiğinde alt kümede yeralan ve yer değiştirilebilecek bir örnek olup olmadığı araştırılır. Bulunamadığı durumda veri kümesi genişletilir. Veri kümesinin boyutunun belirli bir üst sınırı aşmaması için en eski örnekten başlayarak fazlası varsa çıkartılır [111, 113]. ANNCAD yaklaşımı, düşük bellekle çalışabilmek için matris temelli yapı kullanmıştır. Örnekleri özniteliklerine göre farklı birimlere kaydederek her sınıfa özel ayrı yoğunluk haritası tutarak, veri akışı için örnek tabanlı bir yaklaşım geliştirmiştir. Güncel verilerin sınıflandırmada etkisini yüksek tutabilmek için eski veriler için indirgeme çarpanı kullanmıştır. Bu yöntem kademeli kavram sapması için etkili olurken, ani veri değişikliklerinde başarısız kalmaktadır [112, 114].

Topluluk öğrenme algoritmaları, çokseslilik ve oylama kavramlarının makineli öğrenmeye uyarlanması ile elde edilmiş öğrenme yaklaşımlarıdır. Gerçek hayatta bir uzman ne kadar bilgili olursa olsun karar verme sürecinde hata yapabilir. Topluluk algoritmaları, tek bir uzman yerine birden çok uzmanı barındıran bir grup tarafından karar verilmesinin hata olasılığını en aza indireceği hipotezine dayalıdır. Topluluk öğrenme algoritmaları bir tek sınıflandırıcı model yerine birden çok alt model öğrenir. Karşılan yeni durum için alt modellerin vereceği kararlar değerlendirilerek çoğunluğun sınıf tahmini tercih edilir. Topluluk algoritmaları hata riskini birden çok alt modele paylaştırdığından dolayı daha kararlı ve yüksek doğruluk oranına sahip sınıflandırma sistemleri elde etmektedir. En temel topluluk algoritmaları, Bagging ve AdaBoost algoritmalarıdır [115–117]. Bu algoritmalar eğitim örnekleri üzerinde yeni örneklemeler

yaparak elde ettiği veri kümeleri ile farklı alt modelleri eğitmektedir. Bagging algoritması, her bir alt model eğitimini eğitim kümesinden farklı bootstrap örnekleme yaparak gerçekleştirir. Karar alt modeller arasında yapılan oylama ile belirlenir. Boosting algoritması ise alt modelleri sırasıyla eğitir. Eğitimde kullanılacak örnekler ağırlıklandırılır ve her bir alt modelin eğitimine olan etkisi değiştirilir. Bir önceki alt model tarafından karşılanan örneklerin ağırlığı düşürülerek sonraki alt modelin öğrenimine olan etkisi azaltılır. Sınıf tahmini yapılırken Boosting algoritmasında oylama yoluyla alt modeller birlikte karar vermektedir. Ancak alt modellerin eğitimde elde ettiği başarıyla orantılı şekilde sınıf kararında ağırlığı bulunmaktadır. Her iki klasik topluluk öğrenme algoritması da sabit veri kümesi üzerinde kullanılmaktadır.

Veri akışının çevrim-içi sınıflandırılabilmesi için Online Bagging ve Online Boosting topluluk öğrenme yaklaşımları geliştirilmiştir [118]. Online Bagging, her yeni örneği farklı alt modeller için rastgele sayıda kopyalayarak kullanır. Bagging algoritmasının bir örneği her bir alt model için kopyalama sayısı Binom dağılımına uyduğu için verinin sürekli olmasından dolayı kopyalama sayısı sonsuza gitmekte, dolayısıyla akışının veri dağılımı Poisson dağılımına benzemektedir. Yeni gelen verinin alt modellere etkisi farklı olmaktadır. Bunun için Poisson(1) dağılımı çerçevesinde yeni gelen verinin her alt model için kaç kez çoğaltılacağına karar verilir ve eğitim gerçekleştirilir. Online Boosting algoritması, yine Poisson(1) dağılımı kullanarak sürekli çalışabilmesi için yeni gelecek verilerin alt model eğitimindeki ağırlıklarını günceller ve eğitimi gerçekleştirir [118].

Bir başka çevrim-içi topluluk yaklaşımı SEA, gelen ardışık verileri yeterli sayıya ulaşıncaya kadar biriktirir ve bununla alt model eğitimi gerçekleştirir. Karar mekanizması alt modellerin verdiği kararların çoğunluğuna göre belirlenir. Bir kavram sapması tespit edilirse geçersiz olan alt model yeni öğrenilen modelle değiştirilir [119]. ACE algoritması çoğunluğun oranlanmış tercihleri ile karar veren bir topluluk öğrenme yöntemidir. Algoritma çevrim-içi öğrenme, alt model öğrenme ve değişim tespit sistemi olmak üzere üç bileşen içermektedir. Her yeni veri öncelikle çevrim-içi algoritmanın temel modeli eğitmesinde kullanılır ve veri deposunda biriktirilir. Dağılımda değişim tespit edildiğinde ya da depolanan veriler yeterli miktara ulaştığında yeni bir alt model öğrenimi gerçekleştirilir. Daha sonra çevrim-içi öğrenme yaklaşımıyla güncellenen temel model sıfırlanır ve biriktirilen veriler boşaltılır [120]. Bu yöntemle kavram sapmasına adaptif

çözüm getirmek amaçlanmış, ancak ani bir değişim gerçekleştiğinde eski alt modellerden dolayı algoritmanın doğruluğu düşük kalmıştır. ASHT Bagging algoritması, alt model öğrenimi için Hoeffding ağacı kullanmış bir tür Bagging tabanlı topluluk algoritmasıdır. Diğer bagging yaklaşımlarından farklı olarak, Hoeffding ağaçlarının maksimum boyutu için yeni bir parametre tanımlamış, ağaç bu sınırı aştığında ağacı tamamen ya da bazı düğüm noktalarını silerek model boyutunun aşırı büyümesi engellenmiştir [121]. OCBoosting, klasik AdaBoost algoritmasının sınıflandırma yaklaşımını temel almış yeni örnekler ile modeli güncelleyip hata oranını indirgeyerek çevrim-içi sınıflandırmaya uyarlamış bir algoritmadır. Winnow algoritması ile ilk kez ortaya konulmuş artımlı eğitim kümesi karşısında modeli güncelleme yaklaşımını kullanmıştır. Algoritma her bir alt sınıflandırma modeli için ağırlık tutar, yeni gelen verilerle birlikte modellerin ağırlıklarını günceller [122]. ECSMiner, zaman içinde nadir biçimde karşılaşılan sınıfları doğru sınıflandırabilmek amacıyla, yeni bir sınıf tabanlı topluluk algoritması olarak ortaya konulmuş bir algoritmadır. Veriler veri grupları biçiminde eğitime alınıp her bir sınıf için ayrı mikro sınıflandırıcılar geliştirilmiştir. Böylece sınıfların her biri için eğitilmiş modeller saklanır [123]. AUE, tekrarlayan, ani ve kademeli olmak üzere farklı kavram sapmalarına karşı duyarlı biçimde kendini adapte ederek tahmin doğruluğunu yüksek tutmayı amaçlayan bir çevrim-içi topluluk tabanlı sınıflandırma algoritmasıdır. Daha önce geliştirilmiş blok bazlı öğrenme yaklaşımlarının kademeli değişim karşısındaki üstünlüğü ile, artımlı öğrenme yaklaşımlarının ani değişimler karşısında gösterdikleri başarıyı birleştiren yeni bir yaklaşım ortaya konulmuştur. AUE algoritması eğitim işlemini blok bazlı gerçekleştirmiştir. Yeni gelen veriler biriktirilir ve sabit boyutta bir grup elde edilince eğitim işlemine geçilir. Veri bloku ile öncelikle yeni bir alt model eğitilir. Ayrıca eski alt modeller yeni veriler kullanılarak güncellenir. Alt model sayısı belirlenen sayıyı aştığında en düşük doğruluğa sahip alt model çıkartılır [124]. OAUE, AUE algoritması gibi farklı kavram sapmalarına karşı adaptif biçimde çalışabilen bir algoritma olarak ortaya konulmuştur. Blok bazlı algoritmaları temel almakla birlikte her yeni gelen veri ile alt modelleri eğiterek artımlı öğrenme yaklaşımını eklemektedir. Alt modelleri yeni gelen veriler ile eğitmek ve karar üzerindeki ağırlıklarını güncellemek amacıyla artımlı hata tabanlı ağırlık fonksiyonu adı verilen bir yaklaşım AUE'den farklı olarak ortaya konulmuştur [83].

4.1. Online-ABCMiner Algoritması

Online-ABCMiner, bir yandan mevcut modelle sınıf kararı verebilirken diğer yandan da sınıflandırma modelini sürekli iyileştiren ABC'ye dayalı çevrim-içi bir sınıflandırma algoritmasıdır. Online-ABCMiner algoritmasının sahip olduğu özellikler ve avantajlar şu şekilde sıralanabilir:

- Denetimli Öğrenme: Online-ABCMiner makineli öğrenme yaklaşımlarından denetimli öğrenmeyi kullanır. Çevrim-içi çalışması esnasında örneklerin sınıf tahmini yapılırken sonra öğrenilecek gerçek sınıfı yardımıyla da denetimli öğrenme gerçekleştirilir.
- Michigan Gösterimi: Online-ABCMiner algoritmasının her bir yiyecek kaynağı bir kuralı temsil etmektedir.
- Hibrit Kodlama: Çözüm araştırmasında her bir öznitelik için uygun veritipi kullanılır.
- Ödüllü Yarışma ve Çok-Durumlu Araştırma: Algoritma çok kazananlı yarışma yöntemiyle çok-durumlu araştırma kabiliyetine sahiptir. Bu yöntemde çözüm popülasyonu eğitim kümesiyle karşılaştırılır ve doğru tahminde bulunan çözümler her örnek için bir puan kazanacaktır. Aynı örneği sınıflandıran iki çözüm ortaya çıkarsa ödülü daha kaliteli olan çözüm kazanır. Yarışma sonucunda genelleşmiş ve çözüm uzayının farklı bölgelerini kapsayan çözüm alt kümesi sınıflandırma modelini teşkil eder.
- Sabit bellek kullanımı: Online-ABCMiner algoritmasında sabit uzunlukta bellek kullanımı Şekil 4.2'de gösterilen veri penceresi kullanılarak gerçekleştirilmiştir. Veri akışı ile gelen her yeni örnek veri penceresine eklenirken, eskiler çıkartılır. Böylece açık uçlu veri akışı sınırlı bellek kapasitesi içinde işlenir.
- Çevrim-içi öğrenme: Veri akışının sürekliliği nedeniyle gelen veriler bir taraftan sınıflandırılırken modelin geliştirilmesi için de kullanılmalıdır. Online-ABCMiner gelen her yeni veriyle kural kümesi üzerinde gerekli iyileştirmeleri yapar.
- Çevrim-içi tahmin: Klasik öğrenme algoritmaları eğitim verileri ile sınıflandırma modeli öğrenirken farklı örneklerin sınıf tahmininde kullanılamaz. Sınıf

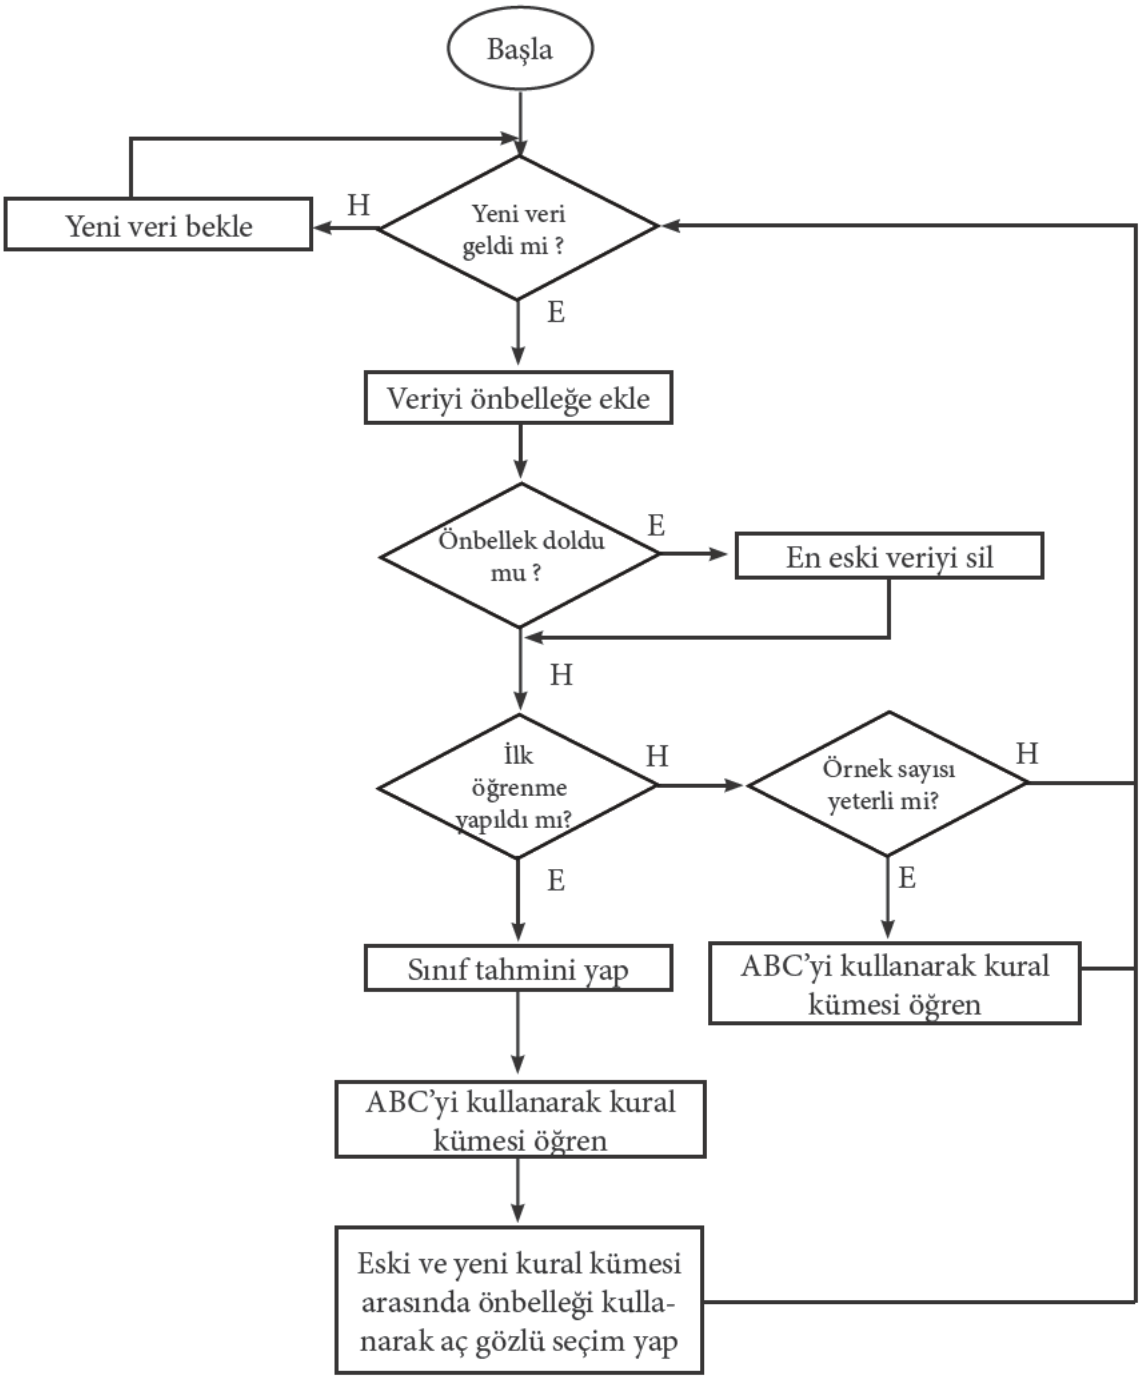


Şekil 4.2. Çevrim-içi eğitimde kullanılan veri penceresi ve veri akışı.

tahmini eğitim tamamlandıktan sonra durağan sınıflandırma modeliyle yapılabilir. Online-ABCMiner algoritması ise anlık kullanışlı bir modele sahiptir ve her yeni gelen veri için sınıf tahmini yapabilmektedir.

- Adaptasyon yeteneği: Online-ABCMiner algoritması kavram sapması durumunda modeli değiştirebilme yeteneğine sahiptir. Veri penceresi yeni gelen verileri eklerken en eski örnekleri önbellekten çıkartır. Bir kavram sapması ortaya çıktığında çözüm popülasyondaki eski çözümlerin kalitesi azalacağından dolayı yeni durumlara uygun biçimde yeni çözümler geliştirilecektir.

Online-ABCMiner algoritmasının akış diyagramı Şekil 4.3'te ve kaba kodu Algoritma 4.1'de verilmektedir. Algoritma veri geldiği müddetçe hem eğitim hem tahmin işlemini sürdürmektedir (2. adım). Algoritmanın girişi sabit uzunluklu veri penceresidir. Yeni gelecek her örnek ile birlikte en eski örnek veri penceresinden çıkartılmakta ve yeni örnek pencerenin sonuna eklenmektedir. Algoritmanın çıkışı ise kullanılmaya hazır bir sınıflandırma modeli ve anlık gelen veriye verilen sınıf tahminidir. Algoritma henüz sınıflandırma modeline sahip değilken çözüm popülasyonuna rastgele başlangıç değerleri ataması yapılır. Önbellekte toplanan veri yeterli sayıya ulaştıktan sonra ABC algoritması ile sınıflandırma kurallarını elde etmek için ilk eğitim işlemi gerçekleştirir (6.-9. adımlar). Sınıflandırma modeli öğrenildikten sonra gelecek her yeni veri için sınıf tahmini gerçekleştirilir (12. adım). Sınıflandırma modelinin veri akışına



Şekil 4.3. Online-ABCMiner çevrim-içi öğrenme süreci akış diyagramı.

uyumluluğunu koruyabilmek için yeni veriler ile çevrim-içi öğrenme yapılır (13.-15. adımlar). Çevrim-içi öğrenme adımında yiyecek kaynaklarına rastgele değer ataması yapılmaz ve ilk öğrenme esnasında geliştirilen yiyecek kaynakları kullanılmaya devam edilir. Bu sayede eskiden öğrenilmiş çözümler yeni veriler kullanılarak adapte edilmeye çalışılır. Keşfedilen $YeniKuralSeti$ ile sınıflandırmada kullanılan $KuralSeti$ veri penceresi karşışında elde ettiği başarılar yardımıyla karşılaştırılır. Aç gözlü seçim ile daha

başarılı kural kümesi hafızada saklanır (16.-19. adımlar). Böylece veri penceresindeki son verileri en doğru biçimde sınıflandırabilen sınıflandırma modeli hafızada tutulur.

Girişler: *Önbellek* : Önbellekte biriktirilen öznitelik-sınıf değerleri örnekleri.
C: İlk öğrenme için gerekli önbellekteki örnek sayısı.
ÖrnekSayısı: Çevrim-içi öğrenme için önbellekte saklanacak toplam veri sayısı.
MCN: Toplam çevrim sayısı.
m: Çevrim-içi öğrenme için çevrim sayısı.
Limit: Görevli arının kaşif arıya dönüşebilmesi için aynı yiyecek kaynağı üzerinde yapacağı toplam araştırma sayısının limit değeri.
initOranı: Başlangıç kuralında niteliğin yer alabilmesi olasılığı.
Çıkış : *KuralSeti*: Algoritmanın keşfettiği ve her yeni gelen örnek ile sürekli güncellediği en doğru kural kümesi.
Data: *adayKuralSeti*: Yiyecek kaynakları alt kümesi (Aday kurallar).
KSBaşarısı: Sınıflandırma kuralları kümesinin, eğitim kümesi için doğru sınıflandırma başarı oranı.
YK: (SN x B) boyutlu çözüm matrisi.

```
1: KuralSeti= []
2: while (YeniÖrnek geldikçe) do
3:     Önbellek = Ekle(Önbellek, YeniÖrnek)
4:     ÖnbellekDolduysaFazlaVeriyiSil(Önbellek, ÖrnekSayısı)
5:     if (ilk öğrenme yapılmadıysa) then
6:         if (önbellekte yeterli örnek biriktiyse (C örnek)) then
7:             KuralSeti = ABCileKuralKümesiÖğren(Önbellek, YK, MCN, initOranı, Limit)
8:             KSBaşarısı= SınıflandırmaBaşarısınıHesapla(KuralSeti, Önbellek)
9:         end if
10:    end if
11:    if (öğrenilmiş bir KuralSeti varsa) then
12:        SınıfKararı = SınıfTahminiYap(KuralSeti,YeniÖrnek)
13:        YeniKuralSeti = ABCileKuralKümesiÖğren(Önbellek, YK, m, initOranı, Limit)
14:        adayBaşarısı= SınıflandırmaBaşarısıHesapla(YeniKuralSeti , Önbellek)
15:        KSBaşarısı= SınıflandırmaBaşarısıHesapla(KuralSeti, Önbellek)
16:        if ((adayBaşarısı > KSBaşarısı) OR
           ((adayBaşarısı = KSBaşarısı) AND (ŞartSayısı(YeniKuralSeti) < ŞartSayısı(KuralSeti)) )) then
17:            KuralSeti= YeniKuralSeti
18:            KSBaşarısı= adayBaşarısı
19:        end if
20:    end if
21: end while
return KuralSeti
```

Algoritma 4.1: Online-ABCMiner algoritması kaba kodu.

İlk ve sonraki çevrim-içi yeniden öğrenme algoritmasının kaba kodu Algoritma 4.2'de verilmiştir. ABC algoritmasına dayalı işlemler sırasıyla yapılır. Yiyecek kaynaklarının değerlendirilmesi için kullanılan eğitim örnekleri veri penceresi içinde tutulan verilerdir. Araştırmaya başlamadan önce örneklerin öznitelik değerleri, $[0, 1]$ arasında normalleştirilir (4. Adım). Başlangıç çözümleri için gerekli rastgele ilk değer atama işlemi sadece ilk öğrenmede yapılır, yeniden öğrenme işlemlerinde yapılmaz (5.-7. adımlar). Daha sonra yiyecek kaynaklarının çözümleri değerlendirilir ve kaliteleri hesaplanır (8. Adım). Bir sonraki aşamada Çözümler arasında ödüllü yarışma gerçekleştirilir (9. adım). Ödül kazanan yiyecek kaynakları ile aday kurallar çıkartılır ve doğruluğu değerlendirilir (10.-11. adımlar). Yeni öğrenmede (MCN) parametresi ile verilen sayı miktarınca, çevrim-içi yeniden öğrenme işleminde ise (m) parametresi ile verilen sayı miktarınca algoritmanın eğitim işlemleri tekrarlanır (13.-29. adımlar).

ABC algoritmasının görevli arı (14. adım), gözetleyici arı (18. adım) ve kaşif arı (26.-29. adımlar) çözüm araştırma işlemleri sırasıyla çalıştırılır. Görevli arılar araştırması tamamlandıktan sonra yeni ile eski yiyecek kaynakları arasında aç gözlü bir seçim işlemi gerçekleştirilir (16. adım). Gözetleyici arılar araştırmasından sonra, eldeki yiyecek kaynakları arasında ödüllü yarışma gerçekleştirilir (19. adım).

Girişler: *eğitimÖrnekleri* : Eğitim için kullanılacak öznitelik-sınıf değerleri örnekleri.
KS : Kolonideki toplam arı sayısı.
Çıkış : *KuralSeti*: Algoritmanın keşfettiği ve her yeni gelen örnek ile sürekli güncellediği en doğru kural kümesi.
Data: *SN*: Araştırılan toplam yiyecek kaynağı sayısı.
B: Araştırma uzayının boyutu.
SayısalNS: Araştırılan problemdeki sayısal öznitelik adedi.
NominalNS: Araştırılan problemdeki nominal öznitelik adedi.
YK, *görevliArılar*, *gözetleyiciArılar*: (SN x B) boyutlu çözüm matrisleri.
normFit, *normFitE*: Yiyecek kaynaklarının sınıflandırma performansları.
YKödül: Yiyecek kaynaklarının sınıf kararları için ödül vektörü.
adayKuralSeti: Yiyecek kaynakları alt kümesi (Aday kurallar).
KSBaşarısı: Sınıflandırma kuralları kümesinin, eğitim kümesi için doğru sınıflandırma başarı oranı.
temelSınıf: Hiç bir kural karşılanmadığında atanacak sınıf değeri.

```
1: SN= KS / 2
2: B= ToplamÖzellikAdedi(NominalNS)+ 2 * SayısalNS
3: KuralSeti= []
4: normEğitim= Normalleştir(eğitimÖrnekleri)
5: if (ilk öğrenme) then
6:     YK= BaşlangıçDeğerleriAta(öznitelikler, initOranı, SN, B)
7: end if
8: normFit= Değerlendir(YK)
9: YKödül= ÖdüllüYarışma(YK)
10: KuralSeti= KurallarıÇıkar(YK, YKödül)
11: KSBaşarısı= SınıflandırmaBaşarısıHesapla(KuralSeti,normEğitim)
12: çevrim= 0
13: while (çevrim < MCN) do
14:     görevliArılar= GörevliArılarAdımı(YK)
15:     normFitE= Değerlendir(görevliArılar)
16:     YK= AçGözlüSeçim(YK, görevliArılar, normFit, normFitE)
17:     normFit= Değerlendir(YK)
18:     YK= GözetleyiciArılarAdımı(YK)
19:     YKödül= ÖdüllüYarışma(YK)
20:     adayKuralSeti= KurallarıÇıkar(YK, YKödül)
21:     adayBaşarısı= SınıflandırmaBaşarısıHesapla(adayKuralSeti, normEğitim)
22:     if ((adayBaşarısı > KSBaşarısı) OR
        ((adayBaşarısı = KSBaşarısı) AND (ŞartSayısı(adayKuralSeti) < ŞartSayısı(KuralSeti)) )) then
23:         KuralSeti= adayKuralSeti
24:         KSBaşarısı= adayBaşarısı
25:     end if
26:     kaşifIndisi= KaşifArıyaDönüşenVarMı(YK, Limit)
27:     if (kaşifIndisi > 0) then
28:         YK[kaşifIndisi,B]= YeniYiyecekKaynağıBelirle()
29:     end if
30:     çevrim= çevrim + 1
31: end while
32: temelSınıf= ArtanÖrneklerdekiMaxSınıfBul(KuralSeti, normEğitim)
33: KuralSeti= TemelSınıfEkle(KuralSeti, default)
return KuralSeti
```

Algoritma 4.2: ABC ile çevrim-içi öğrenme algoritması kaba kodu.

Ödül kazanan yiyecek kaynakları, sınıflandırma kurallarına dönüştürülerek ilgili çevrimin sınıflandırma modeli elde edilir (20. adım). Aday sınıflandırma modelinin eğitim örnekleri üzerindeki sınıflandırma başarısı hesaplanır (21. adım). Aday model ile,

hafızada tutulan en iyi model arasında sınıflandırma başarısı ve şart sayısı üzerinden yapılan karşılaştırma sonrası gerekirse hafızada tutulan en iyi sınıflandırma modeli güncellenir (22.-25. Adımlar). İterasyonlar sonunda elde edilen en iyi çözüm kural kümesi olarak ortaya konulur. Karşılayan bir kural olmayan örnekler içinde en yüksek frekansa sahip sınıf bulunarak (32. Adım) temel sınıf olarak sınıflandırma modeline eklenir (33. Adım). Böylece, veri penceresindeki eğitim örneklerini en doğru sınıflandıran, yeni bir kurallar kümesi elde edilir.

CoABCMiner algoritmasının açıklandığı Bölüm 3'te verilmiş ve Online-ABCMiner algoritmasında kullanılan adımlar ve denklemler bu bölümde tekrar açıklanmayacaktır. Yiyecek kaynaklarının temsili 3.1.3'te verildiği gibi yapılmış ve kalitelerinin hesaplanması Denklem 3.6 ile ve çözümler arası ödüllü yarışma 3.1.5'te açıklandığı gibi hesaplanmıştır. Sınıflandırma kurallarının yiyecek kaynaklarından çıkartılması 3.1.6'da verildiği gibi yapılırken ABC algoritmasının görevli, gözcü ve kaşif arı adımları ile en iyi modelin hafızaya alınması ise 3.1.8, 3.1.10 ve 3.1.9'da açıklandığı gibi gerçekleştirilmiştir.

4.1.1. Online-ABCMiner Algoritmasının Kontrol Parametreleri

Online-ABCMiner algoritması Tablo 4.1'de belirtilen toplam 6 kontrol parametresi içermektedir. Üç kontrol parametresi temel ABC algoritmasında yer alan kontrol parametreleridir: MCN algoritmanın çalışacağı toplam çevrim sayısı, KS araştırma yapan toplam arı sayısı ve $Limit$ ise yiyecek kaynağının terk edilerek kaşif arı görevlendirilmesi için gerekli deneme eşik sayısıdır. $initOranı$ yiyecek kaynaklarının başlangıç değerleri belirlenirken şartın yer alma olasılığını tanımlayan ve kuralların karmaşıklığını belirleyen bir kontrol parametresidir. C kontrol parametresi önbellekte tutulacak toplam örnek sayısını belirler. Veri penceresinde tutulacak bu örnekler

Tablo 4.1. Online-ABCMiner algoritması kontrol parametreleri.

Kontrol Parametresi	Görevi
MCN	İlk öğrenme için toplam çevrim sayısı.
KS	Araştırma yapan toplam arı sayısı.
$Limit$	Görevli arının kaşif arıya dönüşebilmesi için gerekli limit değeri.
$initOranı$	Rastgele başlangıç değerinde her bir şartın yer alma olasılığı.
C	Veri penceresi boyutu.
m	Çevrim-içi yapılacak toplam çevrim sayısı.

çevrim-içi eğitim esnasında yiyecek kaynaklarının kalitelerinin ve kural kümelerinin doğruluğunun hesaplanmasında kullanılır. m kontrol parametresi çevrim-içi öğrenme için ABC algoritmasının yapacağı toplam çevrim sayısını ifade eder. Veri akışı sürekli olduğu için seçilecek toplam çevrim sayısı kısıtlı süre içinde gerçekleştirebilecek kadar olmalıdır.

4.2. Deneyler

Bu bölümde Online-ABCMiner algoritmasının performansını değerlendirmek üzere iki farklı deney düzeneği hazırlanmıştır. Problemler üzerinde çalıştırılması ile elde edilen doğruluk sonuçları farklı algoritmalar ile karşılaştırılmıştır. Online-ABCMiner Java programlama dili kullanılarak diğer algoritmaları da barındıran MOA [125] aracı üzerinde kodlanmıştır. Deneyler Intel(R) Xeon(R) E5 2.5 Ghz 2 işlemcili ve 64 Gb belleğe sahip iş istasyonu bilgisayarda gerçekleştirilmiştir.

Deneyler Tablo EK-1.4'te gösterilen ve detayları EK-1'de verilen Agrawal, Led, Sea, Hyperplane, RandomRBF, RandomTree, Airlines, CovType, Poker ve Power adlı 10 farklı büyük veri akışı sınıflandırma problemleri üzerinde gerçekleştirilmiştir. Deneylerde kullanılan kontrol parametre değerleri Tablo 4.2'de verilmiştir. Veri kümesi örnekleri sırasıyla verilirken algoritmaların sınıflandırma test başarısı ve her adımdaki sınıflandırma modeli hakkında sonuçlar kaydedilmiştir. Değerlendirme yapılırken bu değerlerin ortalamaları, standart sapmaları, medyan, en düşük ve en yüksek değerleri karşılaştırılmıştır.

4.2.1. Online-ABCMiner Algoritmasının Büyük Veri Akışı Test Problemleri Üzerindeki Doğruluk Analizi

Online-ABCMiner, Adaptive MRules ve VFDR kural tabanlı çevrim-içi sınıflandırma algoritmaları problemler üzerinde çalıştırılmış ve sonuçları karşılaştırılmıştır. Tablo 4.3'te algoritmaların çalışması sonucu elde edilen doğruluk oranları ile keşfedilen kural sayıları her bir algoritma için verilmiştir. Şekil 4.4., 4.5., 4.6., 4.7. ve 4.8'de doğruluk değişim grafikleri verilmiştir. Ortalama doğruluk değerleri incelendiğinde Online-ABCMiner algoritmasının Agrawal, Hyperplane, Led, Power, RandomRBF, RandomTree ve Sea problemleri için en yüksek başarı gösterdiği görülmüştür. Airlines ve Poker veri

Tablo 4.2. Deneylerde kullanılan Online-ABCMiner parametre değerleri.

Kontrol Parametresi	Değeri
MCN	1000
KS	30
$Limit$	100
$initOranı$	0,5
C	1000
m	50

kümelerinde diğer algoritmalara göre doğruluk ortalaması geride kalmıştır. Tablodaki kural sayıları incelendiğinde Online-ABCMiner Led ve Power dışında diğer problemler için algoritmalar arasında en az sayıda kural ile modelleyen algoritma olmuştur.

Agrawal veri akışı için Online-ABCMiner algoritmasının üstünlüğü bariz biçimde görülmektedir. Online-ABCMiner %94,11 ortalama doğruluk ile birinci algoritma olurken, VFDR %82,07 oranıyla ikinci, Adaptive MRules %67,34 oranı üçüncü olmuştur. Kural sayıları incelendiğinde 12,5 ortalama kural sayısıyla 31,7 ortalama kurala sahip Adaptive MRules ve 62,6 ortalama kurala sahip VFDR algoritmasından çok daha basit biçimde modellemektedir.

Airlines veri akışı için elde edilen sonuçlar incelendiğinde Online-ABCMiner algoritması diğer iki algoritmaya yakın başarı göstermektedir. VFDR % 63,43; Adaptive MRules % 61,21, Online-ABCMiner ise % 60,97 oranında başarı göstermektedir. Online-ABCMiner algoritması 10,6 kural ile modellerken, VFDR 93,2; Adaptive MRules 210,2 kural ile modellemektedir. Diğerlerine göre az sayıda kural içeren oldukça basit bir sınıflandırma modeli ortaya koyan Online-ABCMiner algoritması sınıflandırma doğruluğunda oldukça yakın bir performans sergilemiştir.

Online-ABCMiner CovType veri akışı için ortalama doğruluk değerleri arasında ikinci, ortalama kural sayısı için birinci olmuştur. %62,49 ortalama doğrulukla birinci olan VFDR algoritmasının ortalama değerine %57,46 ile oldukça yakın bir sonuç elde etmiş ve ortalama 4,5 kural sayısıyla model ortaya koymuştur. VFDR algoritması ise 28,3 ortalama kural sayısına sahip model geliştirmiştir. Adaptive MRules algoritmasına bakıldığında %28,14 ortalama doğruluğa sahip 26,3 ortalama kural sayısı elde edilmiştir.

HyperPlane veri akışı için Online-ABCMiner algoritması %73,06 ortalama doğruluk ve 16 ortalama kural elde etmiştir. Online-ABCMiner algoritmasının ortalama kural değeri

Tablo 4.3. Çevrim-içi kural öğrenme algoritmalarının veri akışları için ortaya koydukları sınıflandırma modellerinin kural sayıları ve doğruluk oranları.

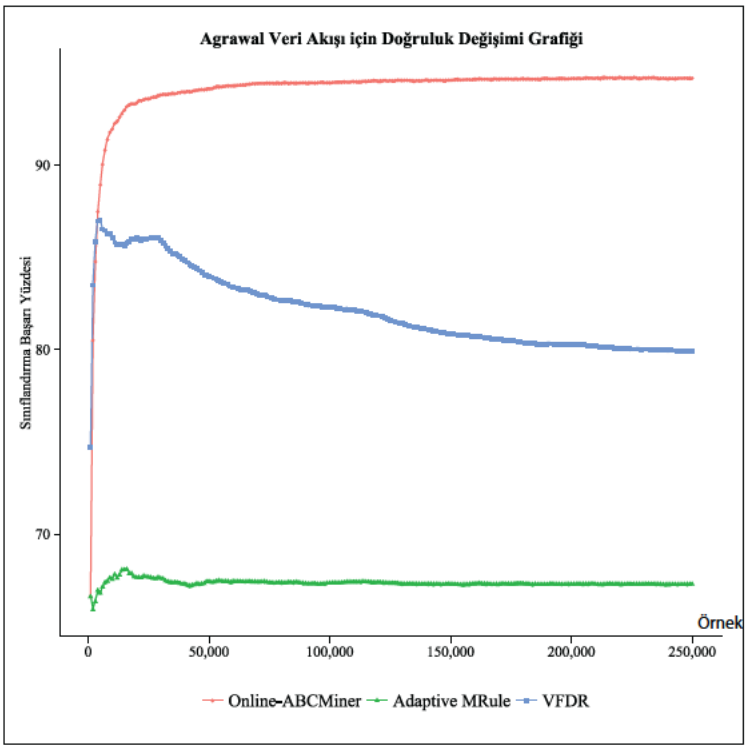
	Doğruluk oranı			Kural sayıları		
Veri Akışı	**Online-ABCMiner**	**Adaptive Mrules**	**VFDR**	**Online-ABCMiner**	**Adaptive Mrules**	**VFDR**
Agrawal						
Ortalama	%94,11 (1)	%67,34 (3)	%82,07 (2)	12,5 (1)	31,7 (2)	62,6 (3)
Standart sapma	%2,21 (3)	%0,19 (1)	%2,06 (2)	1,1 (1)	13,4 (2)	25,2 (3)
Medyan	%94,58 (1)	%67,30 (3)	%81,52 (2)	13,0 (1)	33,0 (2)	71,0 (3)
Min.-Maks.	%66,6-%94,7	%65,9-%68,1	%74,7-%87,0	9-13	4-54	2-95
Airlines						
Ortalama	%60,97 (3)	%61,21 (2)	%63,43 (1)	10,6 (1)	210,2 (3)	93,2 (2)
Standart sapma	%3,49 (2)	%3,81 (3)	%2,24 (1)	1,5 (1)	105,6 (3)	53,1 (2)
Medyan	%60,80 (3)	%60,97 (2)	%63,28 (1)	10,0 (1)	216,5 (3)	94,0 (2)
Min.-Maks.	%55,3-%79,0	%54,3-%79,0	%56,0-%78,9	10-16	3-382	0-182
CovType						
Ortalama	%57,46 (2)	%28,14 (3)	%62,49 (1)	4,5 (1)	26,3 (2)	28,3 (3)
Standart sapma	%6,23 (2)	%6,05 (1)	%8,50 (3)	1,8 (1)	8,6 (2)	16,3 (3)
Medyan	%56,86 (2)	%28,97 (3)	%62,09 (1)	4,0 (1)	25,0 (2)	29,0 (3)
Min.-Maks.	%22,6-%68,7	%9,7-%37,6	%18,5-%71,5	4-16	3-44	1-53
Hyperplane						
Ortalama	%73,06 (1)	%49,91 (3)	%66,41 (2)	16,0 (1)	72,2 (3)	35,0 (2)
Standart sapma	%1,95 (2)	%0,20 (1)	%3,14 (3)	0,2 (1)	38,0 (3)	19,1 (2)
Medyan	%73,45 (1)	%49,93 (3)	%67,75 (2)	16,0 (1)	73,5 (3)	35,0 (2)
Min.-Maks.	%48,7-%73,7	%48,5-%50,3	%50,2-%68,5	15-16	3-135	1-65
Led						
Ortalama	%35,73 (1)	%10,00 (3)	%16,32 (2)	14,9 (3)	1,0 (1)	2,6 (2)
Standart sapma	%2,92 (2)	%0,22 (1)	%3,53 (3)	0,5 (2)	0,0 (1)	1,6 (3)
Medyan	%36,73 (1)	%10,06 (3)	%17,00 (2)	15,0 (3)	1,0 (1)	2,5 (2)
Min.-Maks.	%10,9-%37,7	%8,8-%10,9	%10,1-%21,1	12-15	1-1	0-5
Poker						
Ortalama	%31,43 (3)	%47,70 (2)	%61,73 (1)	10,3 (1)	63,5 (2)	99,3 (3)
Standart sapma	%5,20 (3)	%2,29 (2)	%1,61 (1)	2,7 (1)	23,5 (2)	52,0 (3)
Medyan	%31,10 (3)	%47,56 (2)	%61,70 (1)	12,0 (1)	63,0 (2)	104,0 (3)
Min.-Maks.	%25,5-%59,7	%41,5-%61,1	%59,0-%75,5	6-14	3-107	2-188
Power						
Ortalama	%10,28 (1)	%4,17 (2)	%4,10 (3)	15,6 (3)	4,5 (2)	0,0 (1)
Standart sapma	%1,51 (3)	%0,01 (1)	%0,19 (2)	0,5 (2)	2,9 (3)	0,0 (1)
Medyan	%10,57 (1)	%4,17 (2)	%4,17 (3)	16,0 (3)	3,0 (2)	0,0 (1)
Min.-Maks.	%4,2-%12,3	%4,2-%4,2	%3,5-%4,2	15-16	1-9	0-0
RandomRBF						
Ortalama	%77,56 (1)	%50,01 (3)	%73,02 (2)	15,2 (1)	61,0 (2)	71,2 (3)
Standart sapma	%2,43 (2)	%0,19 (1)	%3,76 (3)	0,4 (1)	27,0 (2)	39,6 (3)
Medyan	%78,17 (1)	%50,05 (3)	%74,49 (2)	15,0 (1)	66,0 (2)	69,5 (3)
Min.-Maks.	%50,1-%78,3	%49,1-%50,2	%48,1-%75,0	14-16	3-99	0-142
RandomTree						
Ortalama	%74,50 (1)	%42,00 (3)	%68,49 (2)	12,3 (1)	108,4 (3)	38,8 (2)
Standart sapma	%2,99 (3)	%0,50 (1)	%1,51 (2)	0,7 (1)	54,1 (3)	19,1 (2)
Medyan	%75,17 (1)	%42,18 (3)	%68,96 (2)	12,0 (1)	114,0 (3)	41,5 (2)
Min.-Maks.	%37,5-%75,5	%37,5-%42,3	%61,7-%70,4	10-14	3-198	1-70
Sea						
Ortalama	%75,21 (1)	%39,36 (3)	%71,24 (2)	12,2 (1)	108,9 (3)	50,9 (2)
Standart sapma	%2,99 (3)	%0,20 (1)	%1,20 (2)	1,2 (1)	56,9 (3)	25,5 (2)
Medyan	%75,95 (1)	%39,32 (3)	%71,66 (2)	13,0 (1)	110,0 (3)	56,0 (2)
Min.-Maks.	%38,6-%76,3	%38,6-%40,3	%61,8-%72,0	8-13	3-208	2-91
Alg. Ortalama	**(1,5)**	(2,7)	(1,8)	**(1,4)**	(2,3)	(2,3)

diğer algoritmalara göre daha basitken diğer taraftan da ortalama doğruluk değeri daha yüksek elde edilmiştir. VFDR algoritması %66,41 doğruluk ve 35 kural; Adaptive MRules algoritması ise %49,91 doğruluk ve 72,2 ortalama kural değeri elde etmiştir.

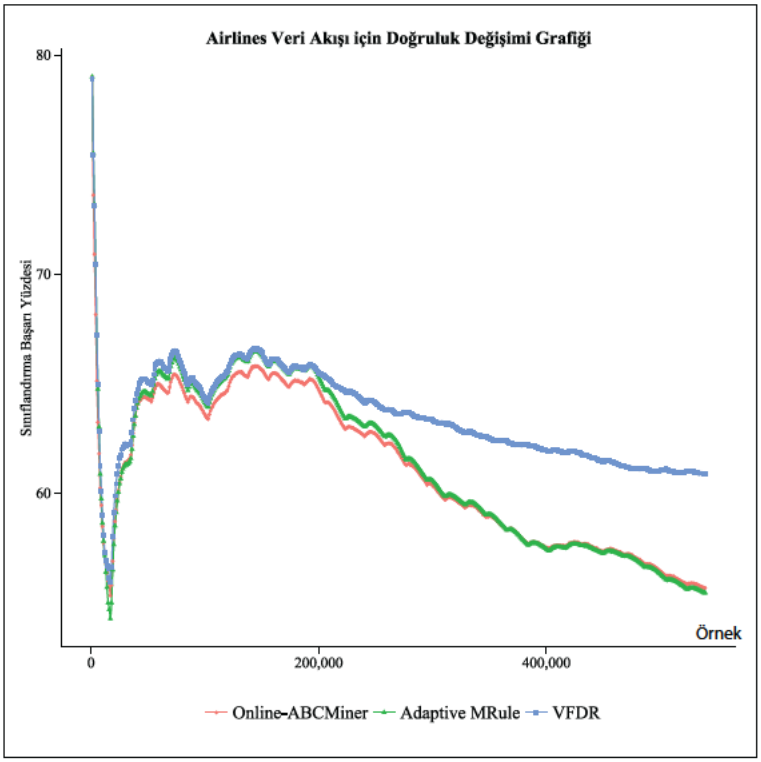
%20 gürültüye sahip Led veri akışı için algoritmaların elde ettiği sonuçlar incelendiğinde 14,9 ortalama kural değerine sahip Online-ABCMiner algoritmasının sınıflandırma modeli %35,73 doğruluğa sahiptir. Adaptive MRules algoritması tek kural sayısı ile birinci olmuş ancak bu sayı 10 sınıfa sahip problemi öğrenemediğini ifade etmektedir. 10 farklı sınıftan sadece birisini temsil eden kural ortaya koyduğundan dolayı elde ettiği başarı doğal olarak %10'da kalmıştır. Dolayısıyla Adaptive MRules algoritması Led veri akışı öğrenimi için kullanılamamış ve sınıflandırma modeli geliştirememiştir. VFDR algoritmasının elde ettiği sonuçlar incelendiğinde ise %16,32 ortalama doğruluk değeri ve 2,6 ortalama kural sayısıyla 10 sınıf için model öğrenemediği gözlemlenmiştir. Led veri akışı hem gerçek öznitelik değerlerine uygulanan %20 gürültü nedeniyle hem de rastgele değer alan 17 anlamsız öznitelik içerdiği için oldukça zor bir problemdir. Online-ABCMiner algoritmasının başarı oranlarının bu şekilde düşük çıkmasıyla beraber gürültü ve ilgisiz öznitelikler karşısında diğer algoritmalara göre daha kararlı olduğu gözlemlenmektedir.

Poker veri akışı için VFDR algoritması %61,73 ortalama doğrulukla birinci, Adaptive MRules %47,70 ile ikinci, Online-ABCMiner algoritması %35,73 değeriyle son sırada yer almıştır. Poker problemi için VFDR ortalama 99,3; Adaptive MRules 63,5; Online-ABCMiner ise 10,3 kural öğrenmiştir. Online-ABCMiner algoritmasının öğrenebileceği kural sayısı KS parametre değeri ile sınırlı olmakla birlikte Tablo 4.3'te görüldüğü üzere bu problem için en fazla 14 kural öğrenebilmiştir. Koloni sayısı 30 verilen Online-ABCMiner algoritması ortalama 10,3 kuralla geliştirdiği sınıflandırma modeli diğer algoritmalara göre yetersiz kalmıştır.

Power veri kümesi için Online-ABCMiner 15,2 ortalama kural sayısı ve %10,28 ortalama başarı değeriyle karşılaştırılan algoritmalara göre daha yüksek bir performans sergilemiştir. Adaptive MRUles ve VFDR sırasıyla %4,17 ve %4,10 ortalama doğruluk elde etmiştir. VFDR algoritmasının Power veri kümesi için hiç kural öğrenemediği görülmektedir. Adaptive MRules algoritmasının elde ettiği ortalama 4,5 kurallı modeller

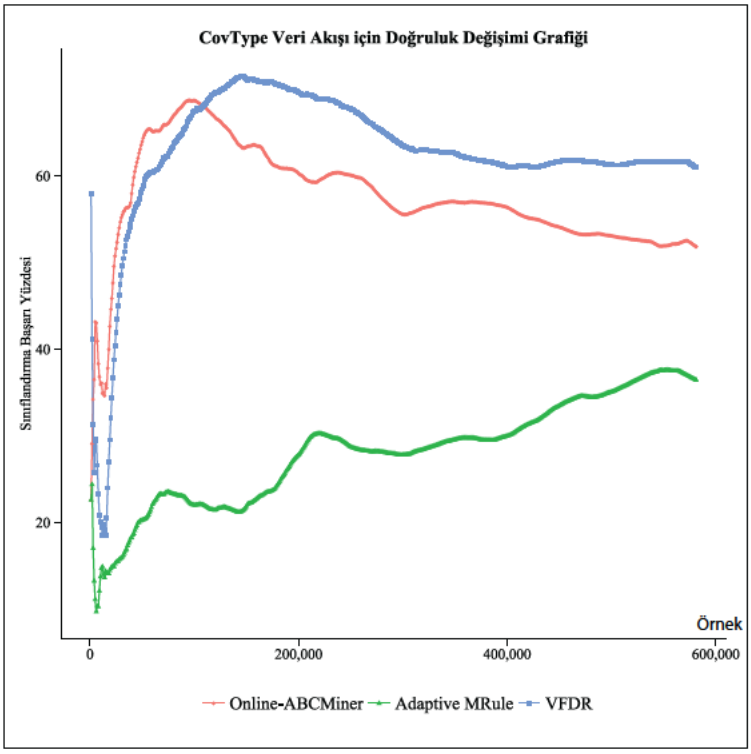


(a)

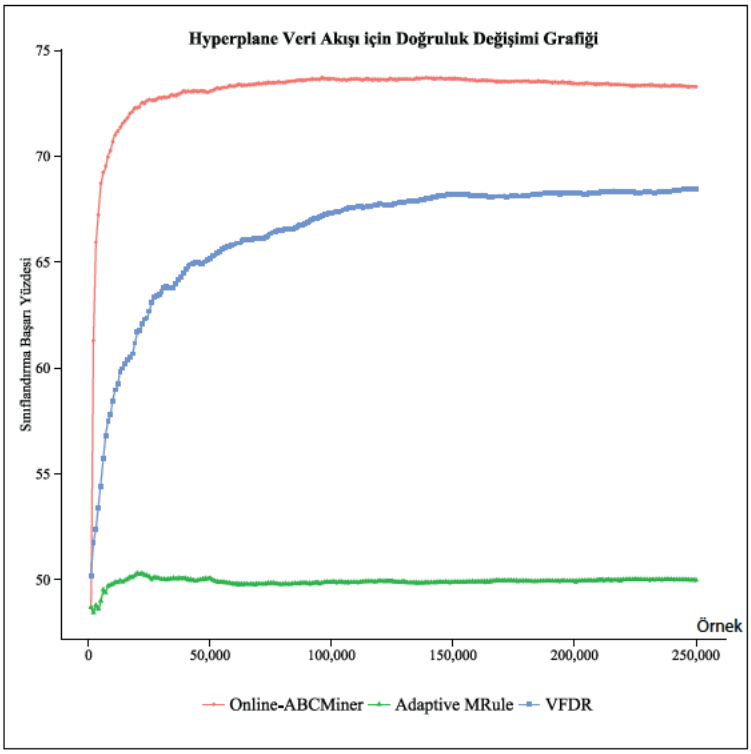


(b)

Şekil 4.4. Agrawal ve Airlines veri akışları için doğruluk değişim grafiği.

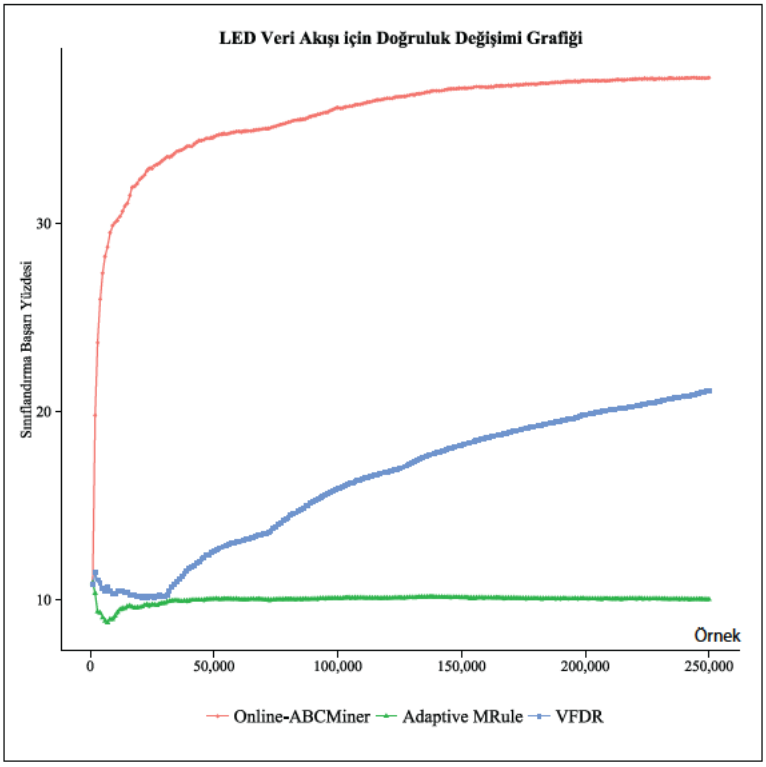


(a)

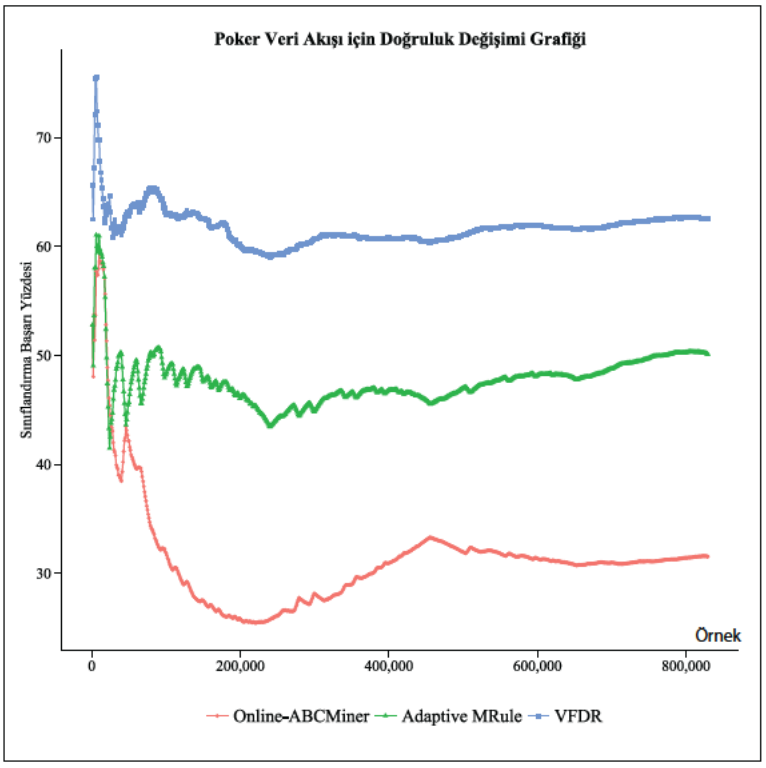


(b)

Şekil 4.5. CovType ve Hyperplane veri akışları için doğruluk değişim grafiği.

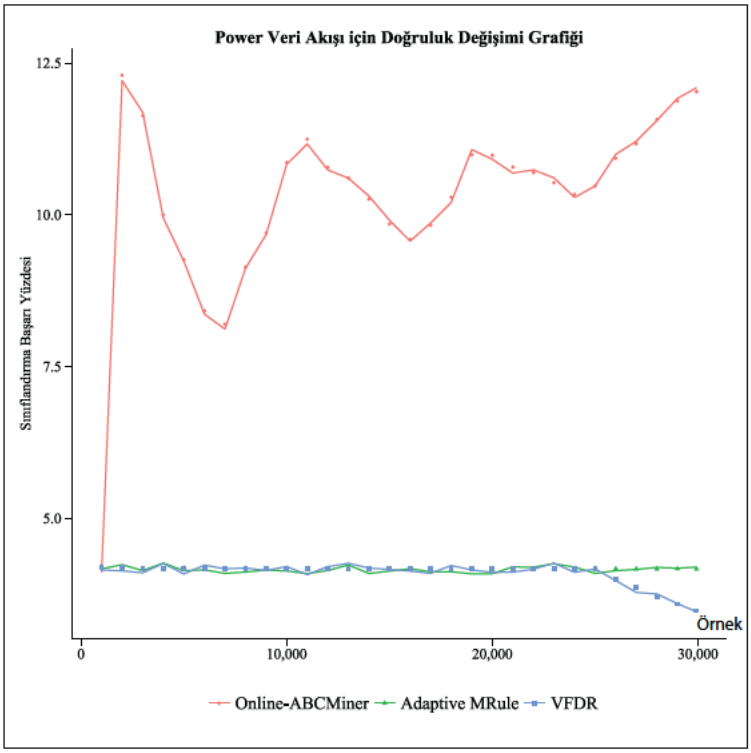


(a)

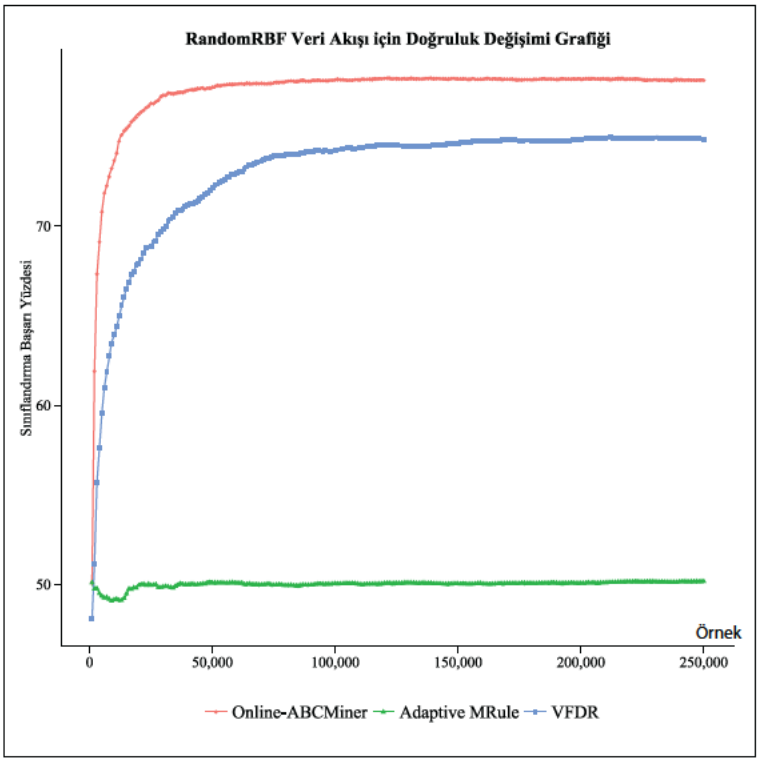


(b)

Şekil 4.6. Led ve Poker veri akışları için doğruluk değişim grafiği.

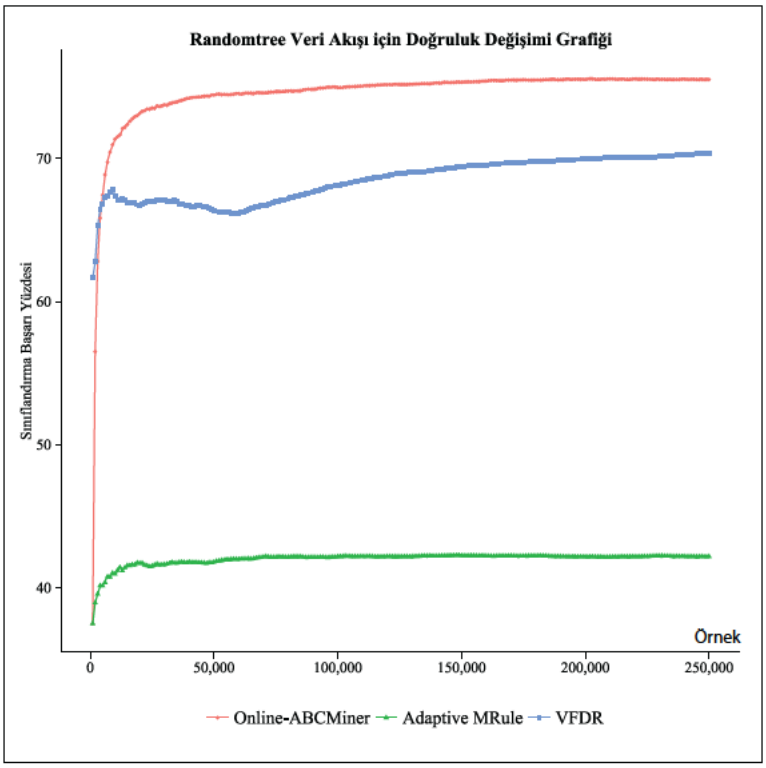


(a)

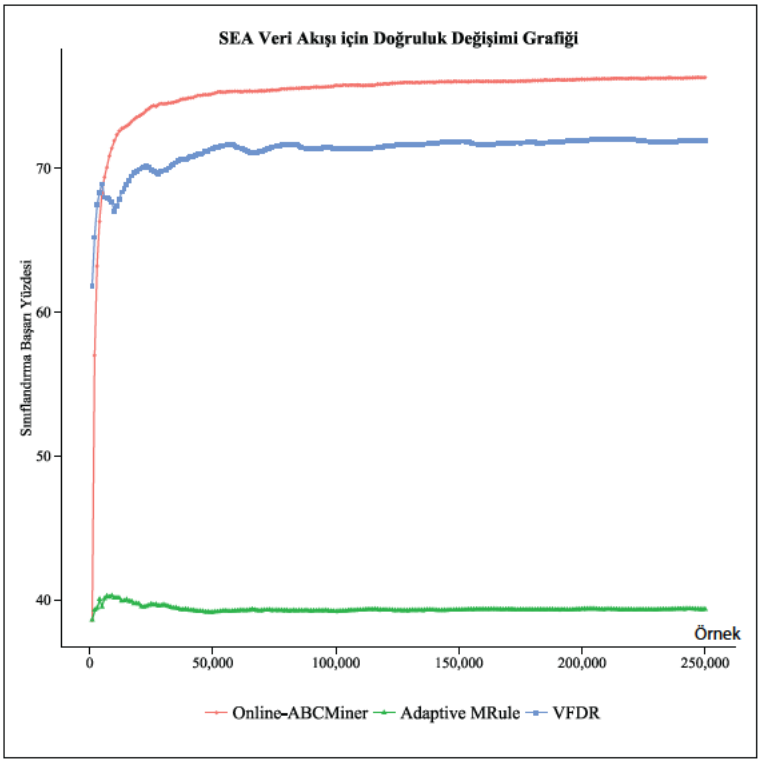


(b)

Şekil 4.7. Power ve RandomRBF veri akışları için doğruluk değişim grafiği.



(a)



(b)

Şekil 4.8. RandomTree ve Sea veri akışları için doğruluk değişim grafiği.

de problemi sınıflandırmak için yeterli değildir. Dolayısıyla Online-ABCMiner Power problemi için kullanılabilecek model geliştiren tek algoritma olmuştur.

Online-ABCMiner RandomRBF veri akışı için ortalama 15,2 kuralla en basit modeli öğrenerek ortalama %77,56 doğruluk değeriyle birinci algoritma olmuştur. VFDR ve Adaptive MRules algoritmalarının ortalama kural sayıları sırasıyla 71,2 ve 61; ortalama doğruluk değerleri de sırasıyla %73,02 ve %50,01 olmuştur. RandomRBF için tek başarılı algoritma az ve yeterli sayıda kural öğrenen ve yüksek doğruluk başarısı elde eden Online-ABCMiner algoritmasıdır.

RandomTree için ortalama 12,3 kurala ve %74,5 doğrulukla başarılı bir model elde eden Online-ABCMiner algoritması birinci olmuştur. Hemen ardından gelen VFDR algoritması 38,2 ortalama kural ile %68,49 doğruluk elde etmiştir. Adaptive MRUles ise 108,4 gibi yüksek kural sayısına rağmen %42 ortalama doğruluk elde edebilmiştir.

Sea veri akışı için Online-ABCMiner 12,2 kural ve %75,21 doğrulukla birinci algoritma olarak yer almıştır. VFDR ve Adaptive MRules algoritmaları sırasıyla 50,9 ve 108,9 kural keşfederek %71,24 ve %39,36 doğruluk elde etmiştir.

4.2.2. Online-ABCMiner Algoritmasının Ani Kavram Sapması Karşısında İyileştirilmesi

Bu bölümde Online-ABCMiner'ın ani kavram sapmaları karşısında performansını korumak için önerilen yeni popülasyon stratejisiyle yapılan deneyler verilecek ve sonuçların değerlendirilmesi yapılacaktır.

Değerlendirme 1'de yapılan deneyler incelendiğinde, Online-ABCMiner algoritmasının kavram sapması içeren Airlines ve Poker problemleri için sonraki örneklerde performansının düştüğü görülmüştür. Poker veri kümesi içindeki örnekler öznitelik değerlerine göre küçükten büyüğe doğru sıralanarak verilmiştir. Örnek olarak veri kümesinin 4 farklı değer alabilen ilk sıradaki (s1) kategorik özniteliği ilk 239.347 örnek için 1; sonraki 215.990 örnek için 2; sonraki 196.360 örnek için 3 ve son 177.516 örnek için ise 4 değerini içermektedir. 1987 ile 2008 yılları arası ABD sınırlarında gerçekleşen ticari uçuş bilgilerini içeren Airlines veri kümesi de yine kavram sapması

içermektedir. Online-ABCMiner'daki veri penceresi en son gelen örnekleri tutmakta ve algoritma çevrim-içi öğrenmeyi bu örnekler yardımıyla yapmaktadır. Öğrenilen kural kümesi veri penceresini en yüksek doğrulukla genelleyen kuralları içerir. Bir kavram sapması çıktığında yeni veriler önceki örneklerden tamamen farklı olacak ve kurallar yeni verileri karşılamayacak ve algoritmanın performansı sonraki tahmin işlemlerinde düşüşe geçecektir.

Online-ABCMiner henüz bir modele sahip olmadığı için başlangıçta ilk öğrenme işlemi yapmaktadır. Bu aşamada rastgele yiyecek kaynakları belirlenerek yeni popülasyon üretilir. İlk model öğrenimi bittiğinde ABC algoritmasının çözüm popülasyonu çevrim-içi öğrenme işlemlerinde kullanılmak üzere saklanır. Veri akışından yeni veriler geldikçe önce model kullanılarak tahmin işlemi yapılır, daha sonra algoritma sınıflandırma modelini geliştirmek amacıyla önceki öğrenme adımından kalan yiyecek kaynaklarını kullanarak ABC algoritmasıyla çözüm araştırır. Online-ABCMiner algoritmasında kullanılan bu yaklaşım önceki verilerle elde edilen bilgi birikiminin sonraki araştırmalara aktarılmasını amaçlamıştır. Bu sayede popülasyondaki çözümlerin bütün örneklerle değerlendirilmiş olması ve genelleştirilmesi elde edilirken çevrim-dışı öğrenmenin doğruluğuna yakın bir performans elde edilmektedir. Çözüm popülasyonunun sonraki çevrim-içi eğitim işlemlerinde olduğu gibi kullanılması yerine, her öğrenme işlemi için rastgele başlangıç popülasyonu üretilerek çalıştırılması amacıyla yeni popülasyon stratejisi önerilmiştir. Yeni popülasyon stratejisi algoritmanın tamamen yeni çözümlere odaklanarak ani kavram sapmaları karşısında adaptasyonunu amaçlamaktadır.

Online-ABCMiner yeni popülasyon stratejisi ile yeniden çalıştırılmış ve elde edilen sonuçlar bir önceki deney sonuçlarıyla karşılaştırılmıştır. Deneylerin karşılaştırmalı doğruluk değişim grafikleri Şekil 4.9, 4.10, 4.11, 4.12 ve 4.13'te gösterilmiştir. Tablo 4.4'te ise doğruluk değerlerinin ortalama, standart sapma, medyan, minimum ve maksimum değerleri ile öğrenilen kuralların ortalama, standart sapma, medyan, minimum ve maksimum sayıları verilmiştir.

Tablo 4.4'de gösterilen deney sonuçları incelendiğinde Agrawal, Hyperplane, Led, RandomRBF, RandomTree ve Sea veri akışları için tek popülasyon stratejisinin yeni popülasyon stratejisi karşısında daha başarılı olduğu, bununla birlikte ani değişimler

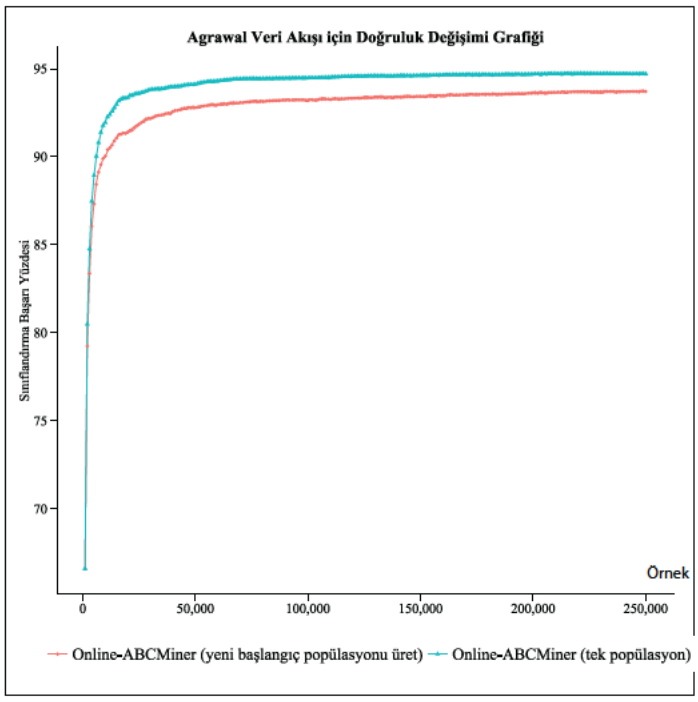
içeren Airlines, Poker ve Power veri akışları için daha düşük doğruluk elde ettiği görülmektedir. Yeni popülasyon stratejisi Airlines veri akışı için ortalama doğruluk değerini %60,97'den %61,56'ya; Poker için %31,43 değerinden %43,76'ya; Power için ise %10,28'den %10,87'ye çıkartmaktadır. Tabloda görüldüğü üzere Poker veri akışının minimum doğruluk değerinde de belirgin bir artış yaşanmıştır. Tek popülasyon stratejisinde %25,5 olan minimum doğruluk değeri yeni popülasyon stratejisi ile %39,7 olmuştur. Power veri akışının maksimum doğruluk değeri yeni popülasyon stratejisiyle %12,3'den %12,8'e yükselmiştir.

Tablo 4.4'te Led veri akışı için verilen ortalama doğruluk değerleri tek popülasyon için %35,73, yeni popülasyon için %28,57 olmuştur. Led veri akışı 17 ilgisiz öznitelik yanında gerçek öznitelik değerlerinde %20 oranında gürültü içermektedir. Gürültü içeren Led veri akışı için eski tecrübelerin tutulduğu tek popülasyon stratejisinin daha başarılı olduğu görülmektedir. Tek popülasyon stratejisi Agrawal için %94,11; CovType için %57,46; Hyperplane için %73,06; RandomRBF için %77,56; RandomTree için %74,50; Sea için %75,21 ortalama doğruluk değeri elde ederek yeni popülasyon stratejisine göre daha yüksek performans göstermiştir.

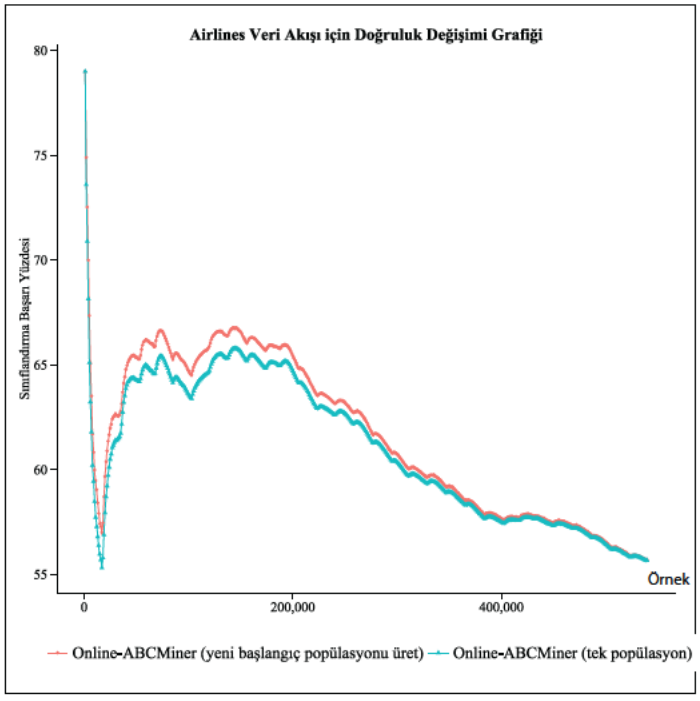
Tablo 4.4'te verilen kural sayılarına bakıldığında Agrawal, Led, Poker, Power, RandomTree ve Sea veri akışları olmak üzere problemlerin çoğunda yeni popülasyon yaklaşımının daha az kural öğrendiği görülmektedir. Poker ve Power'ın daha az kuralla modellenmesi doğruluk üzerine olumlu etkiye sahiptir. Önceki genelleştirmeleri kaybettiğinden dolayı Agrawal, Led, RandomTree ve Sea için yetersiz kalmıştır. Yeni popülasyon stratejisi Airlines veri akışı için daha çok kural öğrenmiştir. Airlines için sadece son örneklere özel ve genelleşmemiş kuralların daha yüksek performans sergilediği görülmektedir.

Elde edilen sonuçlar değerlendirildiğinde kavram sapması içeren bir problem için model geliştirilmesinde eski ve yeni verilerin birlikte kullanılması öğrenilen modelin doğruluğunu düşürmektedir. Online-ABCMiner algoritması her ne kadar veri penceresi içinde eski verileri tutmasa bile, eski bilgiyi yiyecek kaynakları üzerinde saklamaktadır. Bu nedenle her öğrenme işlemi için başlangıç popülasyonunu yeniden üreten yeni popülasyon stratejisi kavram sapması karşısında daha başarılı modeller öğrenmektedir.

Gürültülü ve sabit veri akışları için önceki veriler önemli olduğundan dolayı elde ettiği tecrübeleri çözüm popülasyonu içinde saklayan tek popülasyon stratejisinin daha yüksek doğruluğa sahip kurallar öğrendiği görülmüştür.

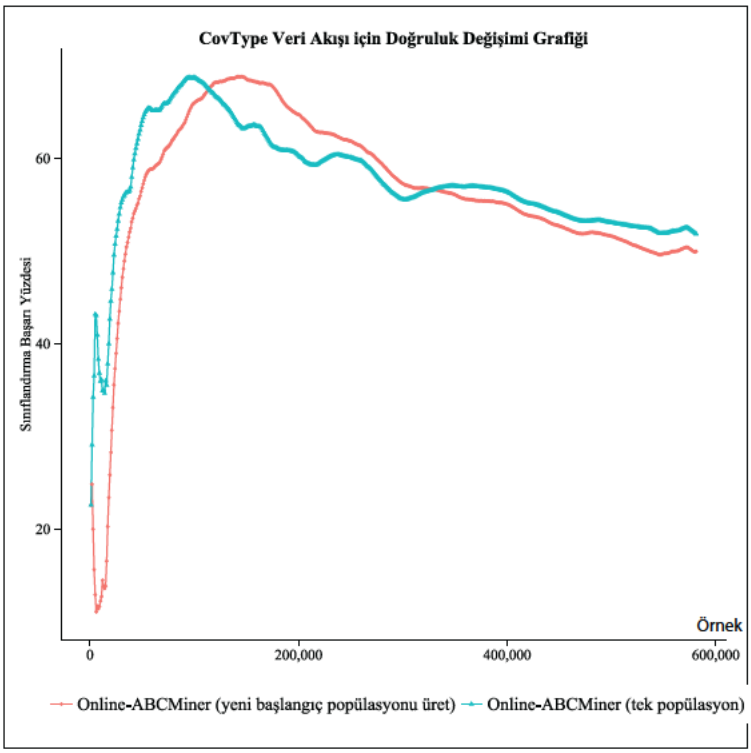


(a)

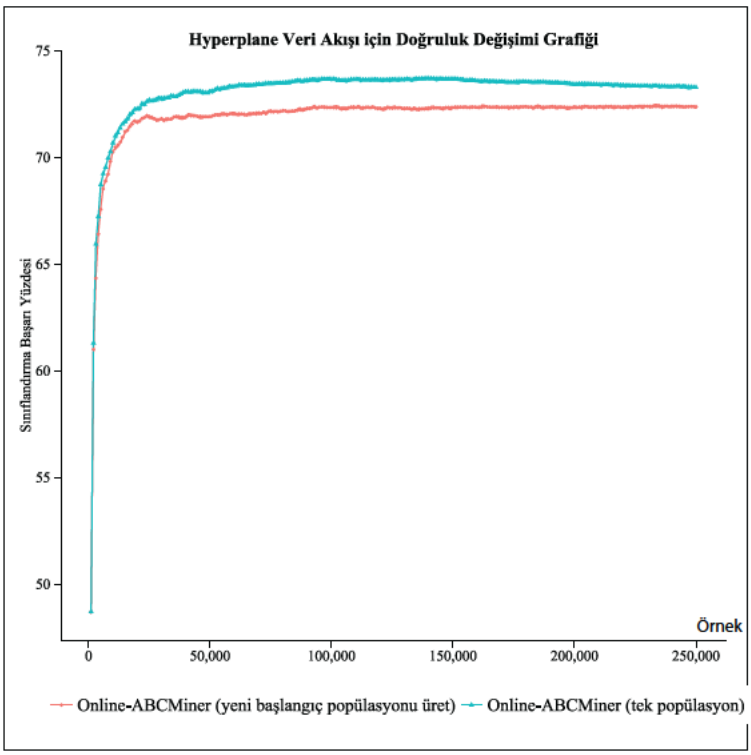


(b)

Şekil 4.9. Agrawal ve Airlines veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği.

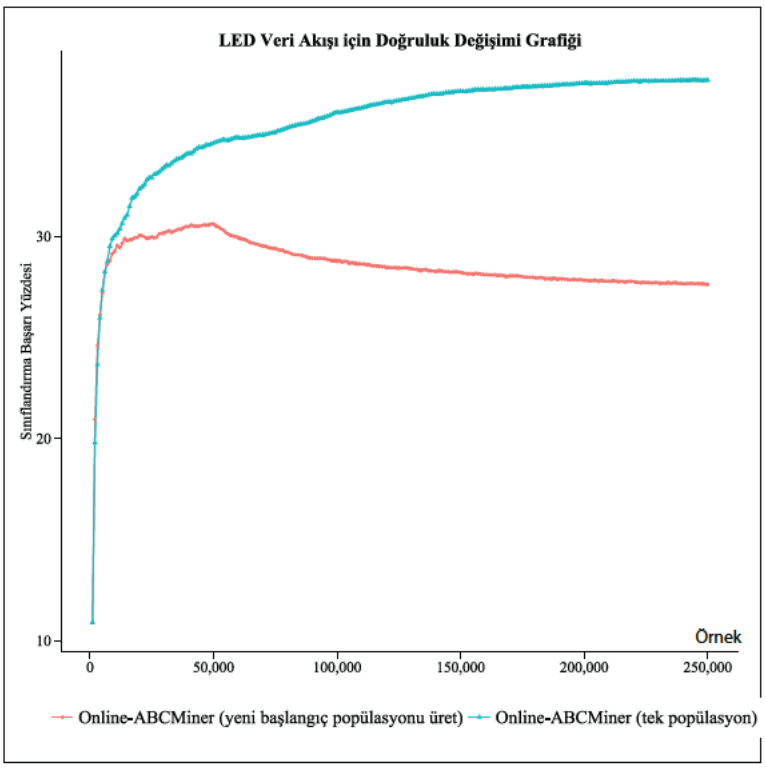


(a)

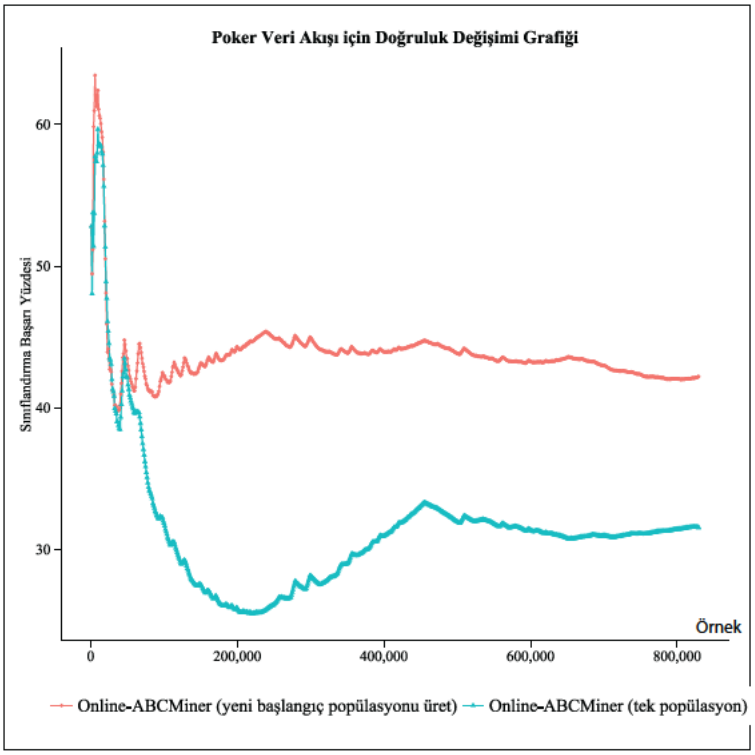


(b)

Şekil 4.10. CovType ve Hyperplane veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği.

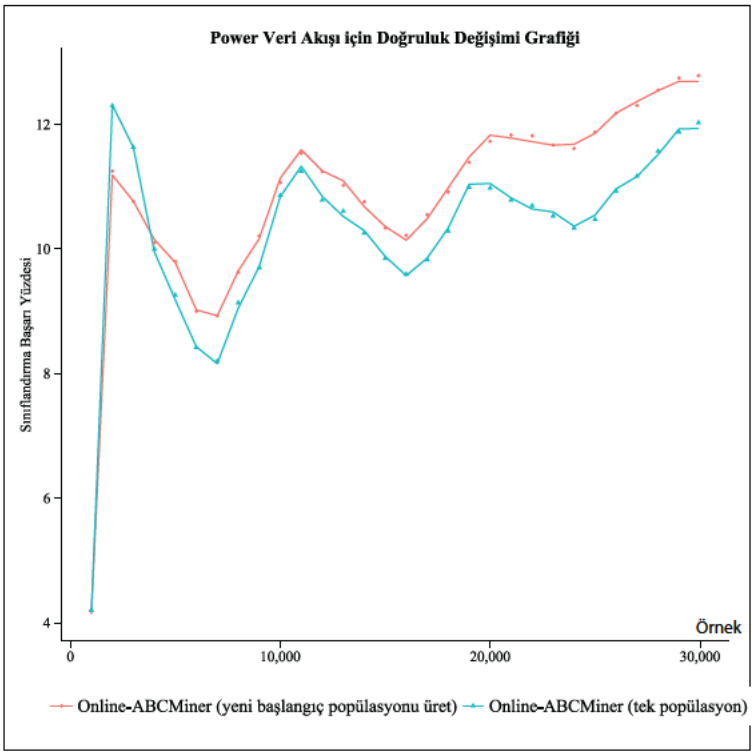


(a)

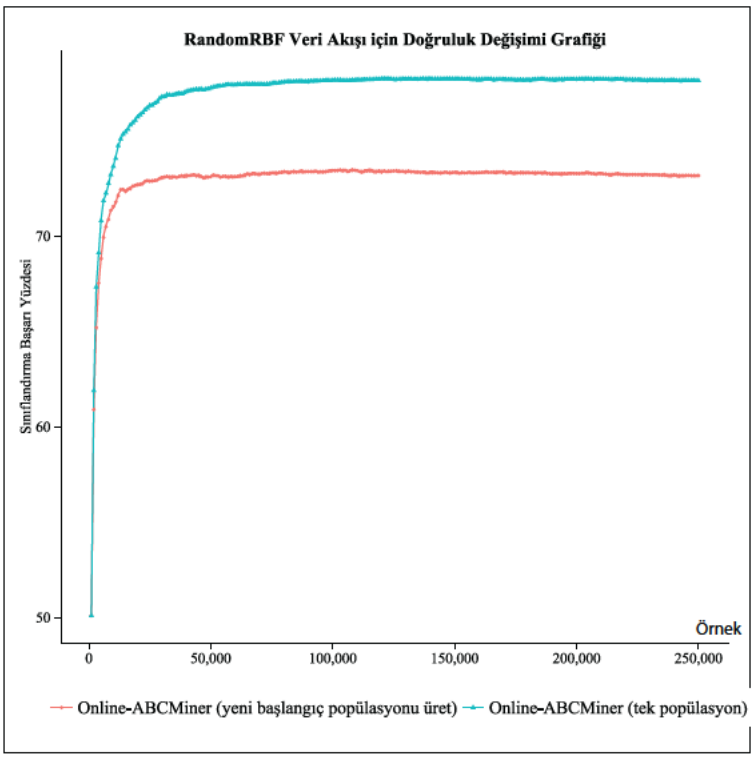


(b)

Şekil 4.11. Led ve Poker veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği.

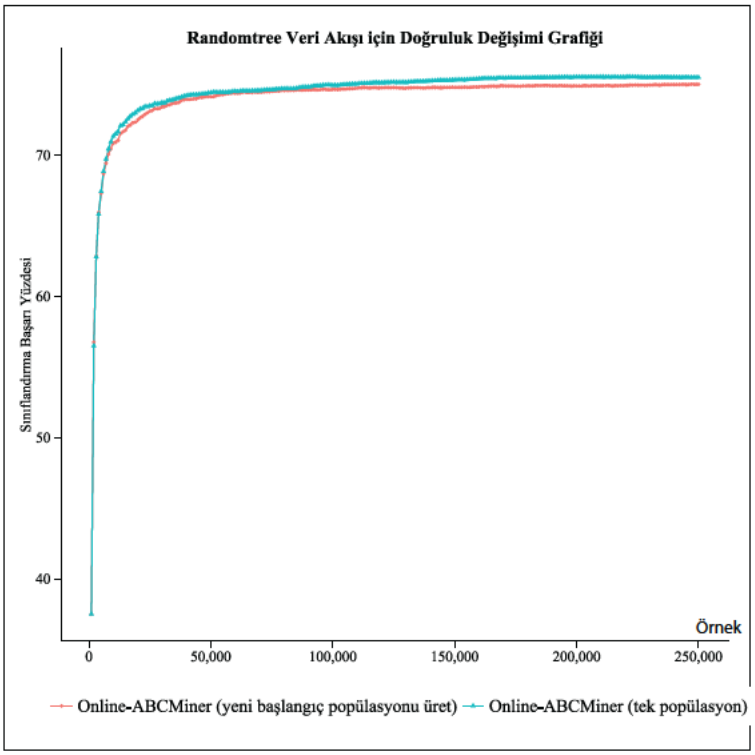


(a)

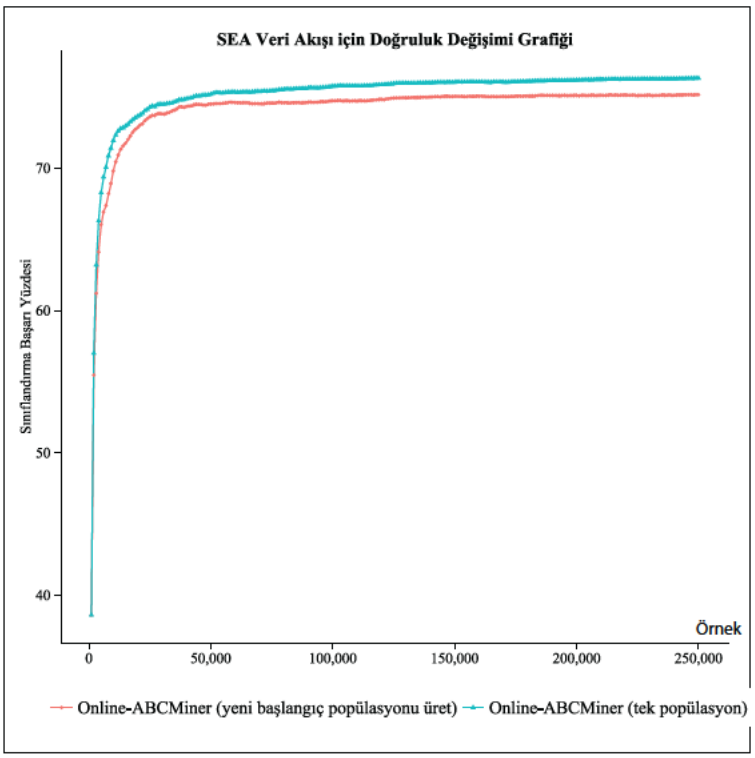


(b)

Şekil 4.12. Power ve RandomRBF veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği.



(a)



(b)

Şekil 4.13. RandomTree ve Sea veri akışları için tek ve yeni popülasyon stratejisiyle elde edilen doğruluk grafiği.

Tablo 4.4. Online-ABCMiner algoritmasının tek ve yeni popülasyon stratejileri kullanılarak elde edilen doğruluk oranı ve kural sayısı istatistikleri.

	Doğruluk oranı		**Kural sayıları**	
Veri Akışı	**Online-ABCMiner (tek popülasyon)**	**Online-ABCMiner (yeni popülasyon)**	**Online-ABCMiner (tek popülasyon)**	**Online-ABCMiner (yeni popülasyon)**
Agrawal				
Ortalama	**%94,11 (1)**	%92,85 (2)	12,50 (2)	**9,08 (1)**
Standart sapma	**%2,21 (1)**	%2,22 (2)	1,08 (2)	**0,96 (1)**
Medyan	**%94,58 (1)**	%93,34 (2)	13,00 (2)	**9,50 (1)**
Min.-Maks.	%66,6-%94,7	%66,6-%93,7	9,0-13,0	8,0-10,0
Airlines				
Ortalama	%60,97 (2)	**%61,56 (1)**	**10,64 (1)**	14,26 (2)
Standart sapma	**%3,49 (1)**	%3,82 (2)	**1,45 (1)**	1,52 (2)
Medyan	%60,80 (2)	**%61,48 (1)**	**10,00 (1)**	15,00 (2)
Min.-Maks.	%55,3-%79,0	%55,7-%79,0	10,0-16,0	11,0-15,0
CovType				
Ortalama	**%57,46 (1)**	%56,30 (2)	**4,47 (1)**	4,54 (2)
Standart sapma	**%6,23 (1)**	%9,88 (2)	**1,84 (1)**	1,96 (2)
Medyan	**%56,86 (1)**	%56,39 (2)	**4,00 (1)**	**4,00 (1)**
Min.-Maks.	%22,6-%68,7	%11,1-%68,8	4,0-16,0	3,0-16,0
Hyperplane				
Ortalama	**%73,06 (1)**	%71,92 (2)	**15,95 (1)**	16,00 (2)
Standart sapma	%1,95 (2)	**%1,84 (1)**	0,21 (2)	**0,00 (1)**
Medyan	**%73,45 (1)**	%72,32 (2)	**16,00 (1)**	**16,00 (1)**
Min.-Maks.	%48,7-%73,7	%48,7-%72,4	15,0-16,0	16,0-16,0
Led				
Ortalama	**%35,73 (1)**	%28,57 (2)	14,86 (2)	**8,00 (1)**
Standart sapma	%2,92 (2)	**%1,56 (1)**	**0,48 (1)**	2,00 (2)
Medyan	**%36,73 (1)**	%28,39 (2)	15,00 (2)	**7,00 (1)**
Min.-Maks.	%10,9-%37,7	%10,9-%30,6	12,0-15,0	7,0-12,0
Poker				
Ortalama	%31,43 (2)	**%43,76 (1)**	10,32 (2)	**3,09 (1)**
Standart sapma	%5,20 (2)	**%2,57 (1)**	2,74 (2)	**0,56 (1)**
Medyan	%31,10 (2)	**%43,50 (1)**	12,00 (2)	**3,00 (1)**
Min.-Maks.	%25,5-%59,7	%39,7-%63,5	6,0-14,0	3,0-11,0
Power				
Ortalama	%10,28 (2)	**%10,87 (1)**	15,63 (2)	**13,30 (1)**
Standart sapma	**%1,51 (1)**	%1,62 (2)	**0,49 (1)**	1,02 (2)
Medyan	%10,57 (2)	**%11,16 (1)**	16,00 (2)	**14,00 (1)**
Min.-Maks.	%4,2-%12,3	%4,2-%12,8	15,0-16,0	12,0-15,0
RandomRBF				
Ortalama	**%77,56 (1)**	%72,97 (2)	**15,18 (1)**	16,00 (2)
Standart sapma	%2,43 (2)	**%1,82 (1)**	0,39 (2)	**0,00 (1)**
Medyan	**%78,17 (1)**	%73,28 (2)	**15,00 (1)**	16,00 (2)
Min.	%50,1-%78,3	%50,1-%73,5	14,0-16,0	16,0-16,0
RandomTree				
Ortalama	**%74,50 (1)**	%74,09 (2)	12,29 (2)	**9,56 (1)**
Standart sapma	%2,99 (2)	**%2,93 (1)**	0,70 (2)	**0,51 (1)**
Medyan	**%75,17 (1)**	%74,77 (2)	12,00 (2)	**10,00 (1)**
Min.-Maks.	%37,5-%75,5	%37,5-%75,0	10,0-14,0	8,0-10,0
Sea				
Ortalama	**%75,21 (1)**	%74,19 (2)	12,20 (2)	**7,23 (1)**
Standart sapma	**%2,99 (1)**	%3,05 (2)	1,17 (2)	**0,47 (1)**
Medyan	**%75,95 (1)**	%74,93 (2)	13,00 (2)	**7,00 (1)**
Min.-Maks.	%38,6-%76,3	%38,6-%75,2	8,0-13,0	6,0-9,0
Alg. Ortalama	**(1,3)**	(1,7)	(1,6)	**(1,4)**

4.2.3. Değerlendirme

Bu bölümde açık uçlu veri akışı üzerinden sınıflandırma modeli öğreniminde kullanabilmek amacıyla yeni geliştirilen ABC'ye dayalı uyarlanır çevrim-içi kural öğrenme algoritması (Online-ABCMiner) açıklanmıştır. Önerilen algoritma Agrawal, Led, Sea, Hyperplane, RandomRBF, RandomTree, Airlines, CovType, Poker ve Power adlı 10 sınıflandırma problemi üzerinde test edilmiş sonuçlar Adaptive Mrules ve VFDR algoritmaları ile karşılaştırılmıştır. Online-ABCMiner algoritmaların problemler üzerinde yapılan başarı sıralamalarına göre 1,5 ortalama ile birinci olmuştur. Power için diğer algoritmalar %4,17 (Adaptive Mrules) ile %4,10 (VFDR) ortalama doğruluk değeriyle başarısız kalırken Online-ABCMiner algoritması %10,28 ortalama doğruluk elde etmiştir. Yine veride %20 gürültü ile 17 rastgele değerli ilgisiz özniteliğe sahip Led problemi üzerinde Online-ABCMiner algoritması %31,43 başarı ortalaması sergilemiştir. Airlines, Poker ve Power problemlerinde yeralan kavram sapması için algoritmada farklı bir popülasyon stratejisi önerilmiştir. Yeni popülasyon stratejisi ile belirtilen problemler için performans yükselmiş sırasıyla %61,56; %43,76 ve %10,87 ortalama doğruluk değerlerine ulaşılmıştır. Test problemleri üzerinde yapılan deneyler sonucunda Online-ABCMiner'ın ani kavram sapması içermeyen gürültülü veri akışları üzerinde diğer algoritmalara göre daha yüksek doğruluğa sahip sınıflandırma modelleri öğrendiği görülmüştür.

5. BÖLÜM

TARTIŞMA, SONUÇ ve ÖNERİLER

5.1. Tartışma, Sonuç ve Öneriler

Sınıflandırma, toplanan veri yığınlarının incelenmesi sonucu sistemin sebep-sonuç ilişkisinin keşfedilmesi ve ardından verilecek bilinmeyen girişlere karşı çıkışın tahmin edilmesi sürecidir. Hem insan hem de makine tarafından anlaşılabilir olmasından dolayı "Eğer-İse" kuralları diğer sınıflandırma modellerine göre belirli üstünlüğe sahiptir. Bununla birlikte literatürdeki algoritmaların çoğu çok sayıda bağımsız öznitelik içeren ya da çok sınıflı karmaşık problemler için basit, kararlı ve başarılı kural tabanlı bir sınıflandırma modeli geliştirmekten uzaktır.

Bu tez çalışmasında veri madenciliği sınıflandırma problemlerinin çözümünde kullanılan kural tabanlı yöntemlerin tanıtımı yapılmıştır. Veri madenciliği, kural tabanlı sınıflandırma yöntemleri ve çevrim-içi sınıflandırma algoritmaları hakkında çok sayıda kaynak incelenerek geniş bir literatür özeti verilmiştir. Bu yöntemlerin test problemleri karşısında gösterdikleri dezavantajları gidermek amacıyla Yapay Arı Koloni (ABC) algoritmasına dayalı Michigan yaklaşımı kullanan üç yeni algoritma geliştirilmiştir. Geliştirilen her yöntemin performansı aynı bölümde diğer algoritmalar ile karşılaştırılarak yorumlanmış ve literatüre olan katkısı açıklanmıştır.

Geliştirilen birinci sınıflandırma algoritması olan ABCMiner, veri kümesini kullanarak kuralları ardışık olarak yani teker teker sırasıyla keşfetmektedir. Keşfedilen kurallar en yüksek doğruluktan en düşüğe doğru sıralanmakta ve sınıflandırma işlemi için kullanılırken yeni örneği ilk karşılayan kuralın sınıfı tahmin olarak değerlendirilmektedir. Önerilen algoritma 13 farklı sınıflandırma problemi üzerinde test edilerek başarısı

literatürdeki algoritmalar ile karşılaştırılmıştır. Karşılaştırmaların daha nesnel olabilmesi için 10 kat çapraz doğrulama yöntemi ile deneyler gerçekleştirilmiştir. Başlangıç çözüm popülasyonlarının meta-sezgisel algoritmaların performansı üzerinde ortaya çıkarabileceği olumsuz etkiyi gidermek amacıyla da deneyler 5 farklı rastgele üretilen başlangıç popülasyonları ile tekrarlanmıştır. Deneylerde elde edilen sonuçlar incelendiğinde ABCMiner algoritmasının diğer algoritmalara göre daha az sayıda kural içeren basit modeller keşfettiği, bununla birlikte sınıflandırma test doğruluğunun diğer algoritmalara yakın olduğu görülmüştür.

Geliştirilen ikinci algoritma olan CoABCMiner, veri kümesini en doğru karşılayan modeli oluşturan kuralların tamamını bir arada, tek çözüm popülasyonu üzerinde ABC algoritmasını bir kez çalıştırarak keşfetmektedir. Popülasyondaki çözümleri en doğru çözümler olarak geliştirebilmek amacıyla işbirliği yapılırken, diğer taraftan da mevcut çözümler arasında yer alabilmek için bir yarış ortaya konulmaktadır. Önerilen ödüllü yarışma yöntemi ile genel çözümü bulmak amacıyla başarı kazanan çözümler arası işbirliği ortaya konulmuştur. CoABCMiner algoritması, hatalı sınıflandırmaları en aza indirgeyen ve az sayıda koşul ile genel biçimde tanımlanmış basit ve en yüksek doğruluğa sahip kuralları araştırırken, bu çözümlerin bir araya gelerek veri kümesi için en yüksek başarı gösteren modelin kurulmasını sağlamaktadır. Bir başka deyişle bütünün parçaları olan alt çözümleri bir arada işbirliği içinde keşfetmektedir. Kurallar bir arada öğrenildiği için geliştirilen sınıflandırma modeli ABCMiner'deki gibi az sayıda kural içermekle birlikte, daha yüksek test başarı oranlarına sahip olmuştur. Bu algoritmanın başarısını karşılaştırmak için 13 farklı test problemi üzerinde 10 kat çapraz doğrulama ve 5 farklı rastgele başlangıç popülasyonu kullanılarak deneyler yapılmıştır. CoABCMiner algoritması diğer algoritmalara göre daha yüksek başarı, daha basit model ve daha düşük standart sapma değerleri elde ederek yüksek bir performans gösterdiği tespit edilmiştir.

ABCMiner ve CoABCMiner algoritmalarının bazı sınıflara ait çok az sayıda örnek içeren dengesiz sınıf dağılımına sahip problemler karşısındaki performansı değerlendirilmek üzere 33 veri kümesi üzerinde testleri yapılmıştır. Bütün test problemleri için test doğruluk sonuçlarının genel ortalaması dikkate alındığında 16 rakip algoritma arasında CoABCMiner 1,82 ortalamayla birinci ve ABCMiner algoritması 4,79 ortalamayla ikinci sırada yer almıştır. Bu sonuçlardan da görüldüğü üzere geliştirilen

sınıflandırma yöntemleri az sayıda veri içeren sınıfları da başarıyla temsil eden kurallar keşfedebilmektedir.

Geliştirilen üçüncü algoritma olan Online-ABCMiner algoritması, veri akışı üzerinde kullanılabilen ve bir taraftan sınıf tahmini yaparken diğer taraftan sınıflandırma modelini iyileştiren, gelen veride ortaya çıkan değişikliklere göre modeli geliştiren bir çevrim-içi kural öğrenme algoritmasıdır. Çevrim-içi algoritmalar sınırlı işlem süresi ve bellek sınırları içinde bir kez işlem yaparak süreklilik arz eden veri akışını anlık sınıflandırabilmeli ve modeli çevrim-içi öğrenebilmelidir. Çevrim-içi öğrenme için karar ağacına ve istatistik tabanlı Bayes yaklaşımına dayalı çok sayıda yöntem geliştirilmiş olmasına rağmen çok az sayıda kural tabanlı yaklaşım tanıtılmıştır. Meta-sezgisel algoritmalar tekrarlı iyileştirme gereksinimlerinden dolayı çevrim-içi öğrenme yöntemlerine çok az sayıda uyarlanabilmiştir.

Online-ABCMiner algoritması ABC'ye dayalı geliştirilen ilk çevrim-içi öğrenme algoritması olma özelliğine sahiptir. Önerilen algoritma 10 farklı veri akışı problemi üzerinde yapılan deneyler ile test edilmiştir. Elde edilen sonuçlar literatürdeki kural tabanlı iki çevrim-içi öğrenme algoritmasının sonuçları ile karşılaştırılmıştır. Online-ABCMiner diğer algoritmalara göre çok az sayıda kural öğrenimi gerçekleştirmiştir. Algoritmanın performansı karşılaştırılan problemler için diğer algoritmalara yakın veya daha yüksek bir performans sergilemiştir.

Tez çalışması süresince mevcut meta-sezgisel temelli kural öğrenme metotlarında yer alan eksiklikler değerlendirilmiş ve gürültülere karşı daha dayanıklı ve yüksek genelleştirme kabiliyetine sahip ABC'ye dayalı yeni kural öğrenimi yöntemleri geliştirilmiştir. Gelecek çalışmalarda önerilen yeni yöntemlerin test problemleri üzerinde elde ettiği yüksek performans ve basitliği gerçek problemler üzerinde test edilebilir. Geliştirilen algoritmalar paralel hesaplamaya dayalı yöntemlerle hızlandırılabilir. CoABCMiner algoritmasında önerilen işbirlik ve yarışma stratejilerine dayalı alt çözümleri bir arada geliştiren ve çok-modlu problemler için çözüm keşfeden yeni yöntemler ortaya konulabilir. Çevrim-içi öğrenme yöntemleri için kural yerine başka model temsilleri kullanılarak daha hızlı ve yüksek doğruluğa sahip yöntemler geliştirilebilir. Çevrim-içi öğrenme sırasında ortaya çıkan veri sapmasını hızlı biçimde öngörecek yeni sezme

yöntemleri önerilebilir ve daha yüksek performanslı yöntemler geliştirilebilir.

KAYNAKLAR

1. Tahir, S.A.M. and Urpilyan, S., 1998. Mahzen-ül Ulum, İstanbul.

2. Şen, Z., 2011. Mühendislikte Felsefe, Mantık, Bilim ve Etik, Su Vakfı.

3. Wikipedia, 2014, Industrial Age. (Web sayfası: **http://en.wikipedia.org/wiki/Industrial_Age**), (Erişim Tarihi: Ocak 2015).

4. Gantz, J. and Reinsel, D., 2012, The Digital Universe in 2020 (IDC) (Web sayfası: **http://www.emc.com/collateral/analyst-reports/idc-the-digital-universe-in-2020.pdf**), (Erişim Tarihi: Haziran 2015).

5. Turner, V., Gantz, J.F., Reinsel, D., ve Minton, S., 2012, The Digital Universe in 2020 (IDC) (Web sayfası: **http://idcdocserv.com/1678**), (Erişim Tarihi: Haziran 2015).

6. Chen, P.S., 1976. The Entity-Relationship Model: Toward a Unified View of Data, **ACM Transactions on Database Systems (TODS)**, **1**(1):9–36.

7. Fry, J.P. and Sibley, E.H., 1976. Evolution of Data-Base Management Systems, **ACM Computing Surveys**, **8**(1):7–42.

8. Ramakrishnan, R. and Gehrke, J., 2003. Database Management Systems, McGraw-Hill, Inc., New York, NY, USA.

9. Piatetsky-Shapiro, G., 2007. Data Mining and Knowledge Discovery 1996 to 2005: Overcoming the Hype and Moving from "University" to "Business" and "Analytics", **Data Mining and Knowledge Discovery**, **15**(1):99–105.

10. Fayyad, U.M., Piatetsky-Shapiro, G., ve Smyth, P., 1996. Advances in Knowledge Discovery and Data Mining, Advances in Knowledge Discovery and Data Mining, chapter From Data Mining to Knowledge Discovery: An Overview, 1–34, American Association for Artificial Intelligence, Menlo Park, CA, USA.

11. Kantardzic, M., 2003. Data Mining: Concepts, Models, Methods, and Algorithms, John Wiley & Sons.

12. SAS-EnterpriseMiner, 2014, Sample, Explore, Modify, Model, Assess (SEMMA). (Web sayfası: **http://faculty.smu.edu/tfomby/eco5385/data/spss/SAS%20_%20SEMMA.pdf**), (Erişim Tarihi: Mayıs 2014).

13. SAS-EnterpriseMiner, 2014, Sample, Explore, Modify, Model, Assess (SEMMA). (Web sayfası: **http://www.sas.com/offices/europe/uk/technologies/analytics/datamining/miner/semma.html**), (Erişim Tarihi: Mayıs 2014).

14. Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., and Wirth, R., 2000. CRISP-DM 1.0, Step-by-step Data Mining Guide, Technical report, SPSS.

15. Han, J. and Kamber, M., 2006. Data Mining Concepts and Techniques, Morgan Kaufmann.

16. Karaboğa, D., 2011. Yapay Zeka Optimizasyon Algoritmaları, Nobel Yayın Dağıtım.

17. Alpaydin, E., 2004. Introduction to Machine Learning, The MIT Press.

18. Berthold, M.R., Borgelt, C., Höppner, F., ve Klawonn, F., 2010. Guide to Intelligent Data Analysis: How to Intelligently Make Sense of Real Data, Springer.

19. Agrawal, R. and Srikant, R., 1994. Fast Algorithms for Mining Association Rules in Large Databases, *Proceedings of the 20th International Conference on Very Large Data Bases*, VLDB'94, 487–499, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.

20. Hall, P., Dean, J., Kabul, I.K., ve Silva, J., 2014. An Overview of Machine Learning with SAS Enterprise Miner, Technical report, SAS Institute, Inc.

21. Karaboga, D., 2005. An Idea Based On Honey Bee Swarm For Numerical Optimization, Technical report, Erciyes University.

22. Holland, J.H., 1975. Adaptation in Natural and Artificial Systems, University of Michigan Press, Ann Arbor, MI.

23. Dorigo, M., Maniezzo, V., Colorni, A., Dorigo, M., Dorigo, M., Maniezzo, V., Maniezzo, V., Colorni, A., ve Colorni, A., 1991. Positive Feedback as a Search Strategy, Technical report.

24. Kennedy, J. and Eberhart, R., 1995. Particle swarm optimization, *IEEE International Conference on Neural Networks, 1995*, volume 4, 1942–1948 vol.4, Perth, WA.

25. Storn, R. and Price, K., 1997. Differential Evolution – A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces, **Journal of Global Optimization**, **11**(4):341–359.

26. Glover, F., 1989. Tabu Search, Part I, **ORSA Journal on Computing**, 190–206.

27. Glover, F., 1990. Tabu Search, Part II, **ORSA Journal on Computing**, **2**(1):4–32.

28. Kirkpatrick, S., Gelatt, C.D., ve Vecchi, M.P., 1983. Optimization by Simulated Annealing, **Science**, **220**(4598):671–680.

29. Farmer, J.D., Packard, N.H., ve Perelson, A.S., 1986. The Immune System, Adaptation, and Machine Learning, **Physica D: Nonlinear Phenomena**, **2**(1-3):187–204.

30. Holland, J.H. and Reitman, J.S., 1977. Cognitive Systems Based on Adaptive Algorithms, **ACM SIGART Bulletin**, **1**(63):49–49.

31. Holmes, J.H., Lanzi, P.L., Stolzmann, W., ve Wilson, S.W., 2002. Learning Classifier Systems: New Models, Successful Applications, **Information Processing Letters**, **82**(1):23–30.

32. Booker, L.B., Goldberg, D.E., ve Holland, J.H., 1989. Classifier Systems and Genetic Algorithms, **Artificial Intelligence**, **40**(1-3n):235–282.

33. Olson, D.L. and Delen, D., 2008. Advanced Data Mining Techniques, Springer-Verlag Berlin Heidelberg.

34. Wikipedia, 2014, Statistics. (Web sayfası: **http://en.wikipedia.org/wiki/Statistics**), (Erişim Tarihi: Ocak 2015).

35. Codd, E.F., 1970. A Relational Model of Data for Large Shared Data Banks, **Communications of the ACM**, **13**(6):377–387.

36. Wikipedia, 2014, Yapay Zeka. (Web sayfası: **http://tr.wikipedia.org/wiki/yapayzeka**), (Erişim Tarihi: Ocak 2015).

37. Kotsiantis, S., Zaharakis, I., ve Pintelas, P., 2006. Machine Learning: A Review of Classification and Combining Techniques, **Artificial Intelligence Review**, **26**(3):159–190.

38. Zhang, T., Ramakrishnan, R., ve Livny, M., 1996. BIRCH: An Efficient Data Clustering Method for Very Large Databases, **ACM SIGMOD Record**, **25**(2):103–114.

39. MacQueen, J.B., 1967. Some Methods for Classification and Analysis of MultiVariate Observations, *Proceeding of the fifth Berkeley Symposium on Mathematical Statistics and Probability*, volume 1, 281–297, University of California Press.

40. Ester, M., Kriegel, H.P., S, J., ve Xu, X., 1996. A Density-based Algorithm for Discovering Clusters in Large Spatial Databases with Noise, *Proceedings of 2nd International Conference on Knowledge Discovery and Data Mining*, KDD'96, 226–231, AAAI, Portland, Oregon, USA.

41. Dempster, A.P., Laird, N.M., ve Rubin, D.B., 1977. Maximum Likelihood from Incomplete Data via the EM Algorithm, **Journal of the Royal Statistical Society, Series B**, **39**(1):1–38.

42. Agrawal, R., Imieliński, T., ve Swami, A., 1993. Mining Association Rules Between Sets of Items in Large Databases, **SIGMOD Record**, **22**(2):207–216.

43. Kurgan, L.A. and Musilek, P., 2006. A Survey of Knowledge Discovery and Data Mining Process Models, **The Knowledge Engineering Review**, **21**(1):1–24.

44. Wang, J., Ed:, 2003. Data Mining: Opportunities and Challenges, Idea Group Publishing.

45. Wirth, R., 2000. CRISP-DM: Towards a Standard Process Model for Data Mining, *Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining*, 29–39, Manchester, UK.

46. Tan, K.C., Yu, Q., ve Ang, J.H., 2006. A Coevolutionary Algorithm for Rules Discovery in Data Mining, **International Journal of Systems Science**, **37**(12):835–864.

47. Safavian, S. and Landgrebe, D., 1991. A Survey of Decision Tree Classifier Methodology, **IEEE Transactions on Systems, Man and Cybernetics**, **21**(3):660–674.

48. Quinlan, J.R., 1986. Induction of Decision Trees, **Machine Learning**, **1**(1):81–106.

49. Quinlan, J.R., 1993. C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers Inc.

50. Breiman, L., Friedman, J., Stone, C.J., Olshen, R., ve Stone, C., 1984. Classification and Regression Trees, Wadsworth & Brooks.

51. Celik, M., Karaboga, D., ve Koylu, F., 2011. Artificial Bee Colony Data Miner (ABC-Miner), *International Symposium on Innovations in Intelligent Systems and Applications*, INISTA'11, 96–100, İstanbul, Türkiye.

52. Clark, P. and Niblett, T., 1989. The CN2 Induction Algorithm, **Machine Learning**, **3**(4):261–283.

53. Michalski, R.S., 1969. On the Quasi-minimal Solution of the General Covering Problem, *Proceedings of the V International Symposium on Information Processing*, FCIP'69, 125–128, Bled, Yugoslavia.

54. Cohen, W.W., 1995. Fast Effective Rule Induction, *In Proceedings of the Twelfth International Conference on Machine Learning*, ML'95, 115–123, Morgan Kaufmann.

55. Bacardit, J., Goldberg, D., ve Butz, M., 2007. Improving the Performance of a Pittsburgh Learning Classifier System Using a Default Rule Learning Classifier

Systems, volume 4399 of Lecture Notes in Computer Science, 291–307, Springer Berlin Heidelberg.

56. Urbanowicz, R.J. and Moore, J.H., 2009. Learning Classifier Systems: A Complete Introduction, Review, and Roadmap, **Journal of Artificial Evolution and Applications**, **2009**.

57. Dejong, K.A., Spears, W.M., ve Gordon, D.F., 1993. Using Genetic Algorithms for Concept-Learning, **Machine Learning**, **13**(2-3):161–188.

58. Grefenstette, J.J., 1988. Credit Assignment in Rule Discovery Systems Based on Genetic Algorithms, **Machine Learning**, **3**(2-3):225–245.

59. Janikow, C.Z., 1993. A Knowledge-Intensive Genetic Algorithm for Supervised Learning, **Machine Learning**, **13**(2-3):189–228.

60. Fernandez, A., Garcia, S., Luengo, J., Bernado-Mansilla, E., ve Herrera, F., 2010. Genetics-Based Machine Learning for Rule Induction: State of the Art, Taxonomy, and Comparative Study, **IEEE Transactions on Evolutionary Computation**, **14**(6):913–941.

61. Smith, S.F., 1983. Flexible Learning of Problem Solving Heuristics Through Adaptive Search, *Proceedings of the Eighth International Joint Conference on Artificial Intelligence - Volume 1*, IJCAI'83, 422–425, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.

62. Corcoran, A. L. ve Sen, S., 1994. Using Real-valued Genetic Algorithms to Evolve Rule Sets for Classification, *Proceedings of the First IEEE Conference on Evolutionary Computation, 1994*, IEEE World Congress on Computational Intelligence, 120–124, Orlando, FL, USA.

63. Geyer-Schulz, A., 1995. Holland Classifier Systems, **ACM SIGAPL APL Quote Quad**, **25**(4):43–55.

64. Wilson, S.W., 1994. ZCS: A Zeroth Level Classifier System, **Evolutionary Computation**, **2**(1):1–18.

65. Wilson, S.W., 1995. Classifier Fitness Based on Accuracy, **Evolutionary Computation**, **3**(2):149–175.

66. Venturini, G., 1993. SIA: A Supervised Inductive Algorithm with Genetic Search for Learning Attributes Based Concepts, volume 667 of Machine Learning: ECML-93, Lecture Notes in Computer Science, 280–296, Springer Berlin Heidelberg.

67. Aguilar-Ruiz, J.S., Riquelme, J.C., ve Toro, M., 2003. Evolutionary Learning of Hierarchical Decision Rules, **Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on**, **33**(2):324–331.

68. Aguilar-Ruiz, J.S., Giraldez, R., ve Riquelme, J.C., 2007. Natural Encoding for Evolutionary Supervised Learning, **IEEE Transactions on Evolutionary Computation**, **11**(4):466–479.

69. Parpinelli, R., Lopes, H., ve Freitas, A., 2002. Data Mining with an Ant Colony Optimization Algorithm, **IEEE Transactions on Evolutionary Computation**, **6**(4):321–332.

70. Sousa, T., Silva, A., ve Neves, A., 2004. Particle Swarm Based Data Mining Algorithms for Classification Tasks, **Parallel Computing**, **30**(5-6):767–783.

71. Greene, D.P. and Smith, S.F., 1993. Competition-Based Induction of Decision-Models from Examples, **Machine Learning**, **13**(2-3):229–257.

72. Jiao, L.C., Liu, J., ve Zhong, W., 2006. An Organizational Coevolutionary Algorithm for Classification, **IEEE Transactions on Evolutionary Computation**, **10**(1):67–80.

73. Giordana, A. and Neri, F., 1995. Search-Intensive Concept Induction, **Evolutionary Computation**, **3**(4):375–416.

74. Wong, M.L. and Leung, K.S., 2000. Data Mining Using Grammar-Based Genetic Programming and Applications, Kluwer Academic Publishers.

75. Džeroski, S., 1996. Inductive Logic Programming and Knowledge Discovery in Databases, Advances in Knowledge Discovery and Data Mining, 117–152, American Association for Artificial Intelligence, Menlo Park, CA, USA.

76. Grefenstette, J.J., Ramsey, C.L., ve Schultz, A.C., 1990. Learning Sequential Decision Rules Using Simulation-Models and Competition, **Machine Learning**, **5**(4):355–381.

77. Karaboga, D. and Akay, B., 2011. A Modified Artificial Bee Colony (ABC) Algorithm for Constrained Optimization Problems, **Applied Soft Computing**, **11**:3021 – 3031.

78. Karaboga, D., 2010. Artificial Bee Colony Algorithm, **Scholarpedia**, **5**(3):6915.

79. Karaboga, D., Gorkemli, B., Ozturk, C., ve Karaboga, N., 2012. A Comprehensive Survey: Artificial Bee Colony (ABC) Algorithm and Applications, **Artificial Intelligence Review**, 1–37.

80. Akay, B. and Karaboga, D., 2009. Parameter Tuning for the Artificial Bee Colony Algorithm, Computational Collective Intelligence. Semantic Web, Social Networks and Multiagent Systems, volume 5796 of Lecture Notes in Computer Science, 608–619, Springer Berlin Heidelberg.

81. Karaboga, D. and Basturk, B., 2007. A Powerful and Efficient Algorithm for Numerical Function Optimization: Artificial Bee Colony (ABC) Algorithm, **Journal of Global Optimization**, **39**(3):459–471.

82. Pace, L., 2012. Beginning R, An Introduction to Statistical Programming, Apress.

83. Brzezinski, D. and Stefanowski, J., 2014. Combining Block-based and Online Methods in Learning Ensembles from Concept Drifting Data Streams, **Information Sciences**, **265**(0):50 – 67.

84. Ganti, V., Gehrke, J., ve Ramakrishnan, R., 2002. Mining Data Streams Under Block Evolution, **ACM SIGKDD Explorations Newsletter**, **3**(2):1–10.

85. Hulten, G., Spencer, L., ve Domingos, P., 2001. Mining Time-changing Data Streams, *Proceedings of the Seventh ACM SIGKDD International Conference*

on Knowledge Discovery and Data Mining, KDD'01, 97–106, ACM, New York, NY, USA.

86. Domingos, P. and Hulten, G., 2000. Mining High-speed Data Streams, *Proceedings of the Sixth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD'00, 71–80, ACM, New York, NY, USA.

87. Shaker, A. and Hüllermeier, E., 2012. IBLStreams: a System for Instance-based Classification and Regression on Data Streams, **Evolving Systems**, **3**(4):235–249.

88. Domingos, P. and Hulten, G., 2003. A General Framework for Mining Massive Data Streams, **Journal of Computational and Graphical Statistics**, **12**(4):945–949.

89. Gaber, M.M., Zaslavsky, A., ve Krishnaswamy, S., 2005. Mining Data Streams: A Review, **SIGMOD Record**, **34**(2):18–26.

90. Ikonomovska, E., Gama, J., ve Dzeroski, S., 2011. Learning Model Trees from Evolving Data Streams, **Data Mining and Knowledge Discovery**, **23**(1):128–168.

91. Kolter, J.Z. and Maloof, M.A., 2007. Dynamic Weighted Majority: An Ensemble Method for Drifting Concepts, **Journal of Machine Learning Research**, **8**:2755–2790.

92. Gama, J., Rocha, R., ve Medas, P., 2003. Accurate Decision Trees for Mining High-speed Data Streams, *Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD'03, 523–528, ACM, New York, NY, USA.

93. Liu, G., Cheng, H.R., Qin, Z.G., Liu, Q., ve Liu, C.X., 2013. E-CVFDT: An Improving CVFDT Method for Concept Drift Data Stream, *2013 International Conference on Communications, Circuits and Systems (ICCCAS)*, volume 1, 315–318, Chengdu, China.

94. Rutkowski, L., Jaworski, M., Pietruczuk, L., ve Duda, P., 2014. The CART Decision Tree for Mining Data Streams, **Information Sciences**, **266**:1–15.

95. Gama, J. and Kosina, P., 2011. Learning Decision Rules from Data Streams, *Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence - Volume Two*, IJCAI'11, 1255–1260, AAAI Press, Barcelona, Catalonia, Spain.

96. Ferrer-Troyano, F., Aguilar-Ruiz, J.S., ve Riquelme, J.C., 2004. Discovering Decision Rules from Numerical Data Streams, *Proceedings of the 2004 ACM Symposium on Applied Computing*, SAC'04, 649–653, ACM, New York, NY, USA.

97. Ferrer-Troyano, F.J., Aguilar-Ruiz, J.S., ve Santos, J.C.R., 2005. Incremental Rule Learning and Border Examples Selection from Numerical Data Streams, **J. UCS**, **11**(8):1426–1439.

98. Wang, P., Wang, H., Wu, X., Wang, W., ve Shi, B., 2007. A Low-Granularity Classifier for Data Streams with Concept Drifts and Biased Class Distribution, **IEEE Transactions on Knowledge and Data Engineering**, **19**(9):1202–1213.

99. Stahl, F., Gaber, M., ve Salvador, M., 2012. eRules: A Modular Adaptive Classification Rule Learning Algorithm for Data Streams, *M. Bramer and M. Petridis, Eds:, Proceedings of the Thirty-second SGAI International Conference on Innovative Techniques and Applications of Artificial Intelligence*, XXIX Research and Development in Intelligent Systems, 65–78, Springer London, UK.

100. Almeida, E., Ferreira, C., ve Gama, J., 2013. Adaptive Model Rules from Data Streams, Machine Learning and Knowledge Discovery in Databases, volume 8188 of Lecture Notes in Computer Science, 480–492, Springer Berlin Heidelberg.

101. Guan, S.U. and Zhu, F., 2005. An Incremental Approach to Genetic-algorithms-based Classification, **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, **35**(2):227–239.

102. Vivekanandan, P. and Nedunchezhian, R., 2011. Mining Data Streams with Concept Drifts Using Genetic Algorithm, **Artificial Intelligence Review**, **36**(3):163–178.

103. Debie, E., Shafi, K., Merrick, K., ve Lokan, C., 2014. An Online Evolutionary Rule Learning Algorithm with Incremental Attribute Discretization, *2014 IEEE Congress on Evolutionary Computation (CEC)*, 1116–1123, IEEE, Beijing, China.

104. Duda, R. and Hart, P., 1973. Pattern Classification and Scene Analysis, Wiley, New York.

105. Zliobaite, I., Bifet, A., Holmes, G., ve Pfahringer, B., 2011. MOA Concept Drift Active Learning Strategies for Streaming Data, *2nd Workshop on Applications of Pattern Analysis*, WAPA'11, 48–55, Castro Urdiales, Spain.

106. Tran, D.H., Gaber, M.M., ve Sattler, K.U., 2014. Change Detection in Streaming Data in the Era of Big Data: Models and Issues, **ACM SIGKDD Explorations Newsletter**, **16**(1):30–38.

107. Tsymbal, A., 2004. The Problem of Concept Drift: Definitions and Related Work, Technical report, Department of Computer Science Trinity College Dublin, Ireland.

108. Kohavi, R., 1996. Scaling Up the Accuracy of Naive-Bayes Classifiers: a Decision-Tree Hybrid, *Proceedings of The Second International Conference on Knowledge Discovery and Data Mining*, KDD'96, 202–207, AAAI Press, Portland, Oregon, USA.

109. Holmes, G., Kirkby, R., ve Pfahringer, B., 2005. Stress-Testing Hoeffding Trees, Knowledge Discovery in Databases: PKDD 2005, volume 3721 of Lecture Notes in Computer Science, 495–502, Springer Berlin Heidelberg.

110. Bifet, A., Holmes, G., Pfahringer, B., ve Frank, E., 2010. Fast Perceptron Decision Tree Learning from Evolving Data Streams, Advances in Knowledge Discovery and Data Mining, volume 6119 of Lecture Notes in Computer Science, 299–310, Springer Berlin Heidelberg.

111. Shaker, A. and Hüllermeier, E., 2012. Instance-Based Classification and Regression on Data Streams, Learning in Non-Stationary Environments, 185–201, Springer New York.

112. Law, Y.N. and Zaniolo, C., 2005. An Adaptive Nearest Neighbor Classification Algorithm for Data Streams, Knowledge Discovery in Databases: PKDD 2005, volume 3721 of Lecture Notes in Computer Science, 108–120, Springer Berlin Heidelberg.

113. Beringer, J. and Hüllermeier, E., 2007. An Efficient Algorithm for Instance-Based Learning on Data Streams, Advances in Data Mining. Theoretical Aspects and Applications, volume 4597 of Lecture Notes in Computer Science, 34–48, Springer Berlin Heidelberg.

114. Gaber, M., Zaslavsky, A., ve Krishnaswamy, S., 2007. A Survey of Classification Methods in Data Streams, Data Streams, volume 31 of Advances in Database Systems, 39–59, Springer US.

115. Breiman, L., 1996. Bagging Predictors, **Machine Learning**, **24**(2):123–140.

116. Quinlan, J.R., 1996. Bagging, Boosting, and C4.5, *Proceedings of the Thirteenth National Conference on Artificial Intelligence*, AAAI'96, 725–730, AAAI Press, Portland, Oregon, USA.

117. Freund, Y. and Schapire, R.E., 1996. Experiments with a New Boosting Algorithm, *Proceedings Of The Thirteenth International Conference On Machine Learning*, ICML'96, 148–156, Morgan Kaufmann, Bari, Italy.

118. Oza, N.C. and Russell, S., 2001. Online Bagging and Boosting, *Artificial Intelligence and Statistics*, AISTATS'01, 105–112, Morgan Kaufmann, Key West, Florida, USA.

119. Street, W.N. and Kim, Y., 2001. A Streaming Ensemble Algorithm (SEA) for Large-scale Classification, *Proceedings of the Seventh ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD'01, 377–382, ACM, New York, NY, USA.

120. Nishida, K., Yamauchi, K., ve Omori, T., 2005. ACE: Adaptive Classifiers-Ensemble System for Concept-Drifting Environments, Multiple Classifier Systems, volume 3541 of Lecture Notes in Computer Science, 176–185, Springer Berlin Heidelberg.

121. Bifet, A., Holmes, G., Pfahringer, B., Kirkby, R., ve Gavalda, R., 2009. New Ensemble Methods for Evolving Data Streams, *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD'09, 139–148, ACM, Paris, France.

122. Pelossof, R., Jones, M., Vovsha, I., ve Rudin, C., 2009. Online Coordinate Boosting, *2009 IEEE 12th International Conference on Computer Vision Workshops*, ICCV'09, 1354–1361, Kyoto, Japan.

123. Al-Khateeb, T., Masud, M., Khan, L., Aggarwal, C., Han, J., ve Thuraisingham, B., 2012. Stream Classification with Recurring and Novel Class Detection Using Class-Based Ensemble, *2012 IEEE 12th International Conference on Data Mining*, ICDM'12, 31–40, Brussels, Belgium.

124. Brzezinski, D. and Stefanowski, J., 2014. Reacting to Different Types of Concept Drift: The Accuracy Updated Ensemble Algorithm, **Neural Networks and Learning Systems, IEEE Transactions on**, **25**(1):81–94.

125. Bifet, A., Holmes, G., Kirkby, R., ve Pfahringer, B., 2010. MOA: Massive Online Analysis, **J. Mach. Learn. Res.**, **11**:1601–1604.

126. Bache, K. and Lichman, M., 2013, UCI Machine Learning Repository. (Web sayfası: **http://archive.ics.uci.edu/ml/**), (Erişim Tarihi: Ocak 2010).

127. Michalski, R. and Chilausky, R., 1980. Learning by Being Told and Learning from Examples: An Experimental Comparison of the Two Methods of Knowledge Acquisition in the Context of Developing an Expert System for Soybean Disease Diagnosis, **International Journal of Policy Analysis and Information Systems**, **4**(2).

128. Thrun, S., Bala, J., Bloedorn, E., Bratko, I., Cestnik, B., Cheng, J., Jong, K.D., Dzeroski, S., Fahlman, S., Fisher, D., Hamann, R., Kaufman, K., Keller,

S., Kononenko, I., Kreuziger, J., Michalski, R., Mitchell, T., Pachowicz, P., Vafaie, Y.R.H., de Welde, W.V., Wenzel, W., Wnek, J., ve Zhang, J., 1991. The MONK's Problems a Performance Comparison of Different Learning Algorithms, Technical report, Carnegie Mellon University, Computer Science Department, Pittsburgh, PA.

129. Wolberg, W.H. and Mangasarian, O.L., 1990. Multisurface Method of Pattern Separation for Medical Diagnosis Applied to Breast Cytology, **Proceedings of the National Academy of Sciences, USA**, **87**:9193–9196.

130. Agrawal, R., Imielinski, T., ve Swami, A., 1993. Database Mining: A Performance Perspective, **IEEE Transactions on Knowledge and Data Engineering**, **5**(6):914–925.

131. Chen, Y., Keogh, E., Hu, B., Begum, N., Bagnall, A., Mueen, A., ve Batista, G., 2015, The UCR Time Series Classification Archive (Web sayfası: **http://www.cs.ucr.edu/~eamonn/time_series_data/**), (Erişim Tarihi: Ocak 2015).

132. Alcala-Fdez, J., Sanchez, L., Garcia, S., Jesus, M.J., Ventura, S., Garrell, J.M., Otero, J., Romero, C., Bacardit, J., Rivas, V.M., Fernandez, J.C., and Herrera, F., 2009. KEEL: a Software Tool to Assess Evolutionary Algorithms for Data Mining Problems, **Soft Computing**, **13**(3):307–318.

133. Garcia, S., Fernandez, A., Luengo, J., ve Herrera, F., 2010. Advanced Nonparametric Tests for Multiple Comparisons in the Design of Experiments in Computational Intelligence and Data Mining: Experimental Analysis of Power, **Information Sciences**, **180**(10):2044 – 2064.

134. Smith, S.F., 1980. A Learning System Based on Genetic Adaptive Algorithms, Doktora Tezi, University of Pittsburgh, Pittsburgh, PA, USA.

135. Pappa, G. and Freitas, A., 2006. Automatically Evolving Rule Induction Algorithms, J. Fürnkranz, T. Scheffer, and M. Spiliopoulou, Eds:, Machine Learning: ECML 2006, volume 4212 of Lecture Notes in Computer Science, 341–352, Springer Berlin Heidelberg.

EK-1

KULLANILAN TEST PROBLEMLERİ

A - UCI Veritabanı

Sınıflandırma problemi için çeşitli öğrenme algoritmaları geliştirilmiş ve bunların birbirine olan üstünlüklerini karşılaştırabilmek için test veri kümelerine ihtiyaç duyulmuştur. Literatürde yapılan yayınlarda farklı veri kümeleri test için kullanılmış ve daha sonra bu veri kümeleri UCI veritabanı altında bir araya getirilmiştir [126–129]. UCI deposu, literatürdeki makineli öğrenme yayınlarında kullanılmış veri kümeleri, veri üreteçleri ve teorilerin bir araya toplandığı Irvine Kaliforniya Üniversitesi bünyesindeki bir makineli öğrenme veritabanıdır. Fiziksel, toplumsal, mühendislik, sosyal bilimler, iş hayatı ve oyun problemi olmak üzere birçok farklı alandan edinilmiş 234 sınıflandırma verisi, 42 kümeleme verisi ve 53 regresyon verisi içermektedir. UCI veri deposunda yer alan ve çalışmalarda kullanılmak üzere seçilen veri kümeleri Tablo EK-1.1'de verilmiştir. Tabloda her bir veri kümesi için veri sayısı *N* ile, eksik değer olup olmadığı *E*, özniteliğin gürültü içerip içermemesi *G*, sınıf değerinin gürültü içerip içermemesi *SG*, ikili/kategorik/sürekli sayı/tam sayı öznitelik sayıları sırasıyla *Nİ,NK,NS,NT* ile, toplam öznitelik sayısı *Top* ile, sınıf özniteliğinin alabildiği değer sayısı *|S|* ile, veri içindeki baskın sınıfın örnek sayısının toplam örnek sayısına oranı *Oran* ile verilmiştir.

- E.coli gen dizisi : E.coli gen dizisi veri kümesi 57 nukleotit gen dizisi içeren pozitif veya negatif işaretlenmiş 106 örnek içermektedir. Her bir gen dizisi özniteliği Adenin, Guanin, Timin ve Sitozin olmak üzere 4 farklı değer almaktadır [126].
- Taşıtlar : Taşıtlar veri kümesinde, silüetleri üzerinden belirlenmiş 18 farklı öznitelik ile 4 türe ait 946 farklı aracın kayıtları bulunmaktadır. Literatürdeki yapılan çalışmalarda 100 kayıt doğrulama yapmak için ayrılmış değerlendirmeler 846 örnek ile yapılmıştır.

Tablo EK-1.1. Deneysel çalışmalarda kullanılan veri kümeleri.

Veri Kümesi	N	E	G	SG	Nİ	NK	NS	NT	Top	|S|	Oran
E.Coli Gen Dizisi	106	Yok	-	-	0	57	0	0	57	2	50,00%
Taşıtlar	846	Yok	-	-	0	0	0	18	18	4	25,77%
Soya Fasülyesi	683	Var	Var	Var	16	19	0	0	35	19	13,47%
Hayvanat Bahçesi	101	Yok	Yok	Yok	15	1	0	0	16	7	40,59%
Mantar	8124	Var	-	-	4	18	0	0	22	2	51,80%
Monkun prob. 2	432	Yok	Yok	Yok	2	4	0	0	6	2	52,78%
Süsen Çiçeği	150	Yok	Yok	Yok	0	0	4	0	4	3	33,33%
Diyabet	768	Yok	-	-	0	0	8	0	8	2	65,10%
Hepatit	155	Var	-	-	13	0	2	4	19	2	79,35%
Meme Kanseri	286	Var	-	-	3	6	0	0	9	2	70,28%
Wisconsin M. K.	699	Var	Var	Var	0	0	0	9	9	2	65,01%
Yeni Tiroid	215	Yok	-	-	0	0	4	1	5	3	69,77%
Lenf Grafisi	148	Yok	-	-	9	6	0	3	18	4	45,3%

Bundan dolayı 846 örnek kullanılmıştır [126].

- Soya fasülyesi : Soya fasülyesi, soya fasülyelerinden ölçülmüş 35 farklı öznitelik değeri ile tanımlanmış ve 19 sınıfa ayrılmış 683 örnek içerir. Deneylerde kullanılan en fazla sınıfa sahip veri kümesidir. UCI veritabanında iki gruba ayrılmış soya fasülyesi veri kümesinin birinci grubu 307 örnek ve ikinci grubu 376 örnek içerir [126].

- Hayvanat bahçesi : Hayvanat bahçesi veri kümesi, bir hayvanat bahçesinde sergilenen 7 farklı sınıfa ayrılmış 101 çeşit hayvanın fiziksel özelliklerini belirten 16 özniteliğe sahip kayıtlar içerir [126].

- Mantar : Mantar veri kümesi, 22 öznitelik değeri ile tanımlanmış zehirli olup olmadığı ile sınıflandırılan Agaricus ve Lepiota familyasına ait 8124 mantar kaydı içermektedir [126].

- Monkun problemi 2 : Monkun problemi 2 veri kümesi öğrenme algoritmalarını karşılaştırmak üzere ortaya konulmuş yapay bir veri kümesidir. 6 kategorik öznitelik ile tanımlanmış 432 örnek iki sınıfa ayrılmıştır. 6 öznitelikten herhangi ikisinin değeri 1 olan veriler 1 ile sınıflandırılmış diğerleri 0 ile sınıflandırılmıştır [126].

- Süsen çiçeği : Süsen çiçeği veri kümesi, 4 öznitelik ile belirtilmiş 3 farklı süsen çiçeği türüne ait 150 kayıt içermektedir [126].

- Diyabet : Johns Hopkins Üniversitesi National Institute of Diabetes and Digestive and Kidney Diseases merkezine ait ve 1990 yılında yayınlanmış Diyabet veri kümesinde şeker hastalarından toplanan 768 örnek verisi bulunmaktadır. Veriler

hasta bilgilerinden oluşan 8 farklı öznitelik ile negatif ve pozitif olmak üzere 2 sınıfa ayrılmıştır [126].

- Hepatit : 1988 yılında yayınlanmış hepatit ile lenf grafisi veri kümeleri Ljubljana'daki Jozef Stefan Enstitüsündeki toplanmış hasta verilerini içermektedir. Hepatit veri kümesi 19 öznitelik ile hastalığın olup olmadığını belirten 2 sınıfa ayrılmıştır [126].

- Meme kanseri : Meme kanseri veri kümesi Ljubljana Tıp Üniversitesi, Onkoloji Enstitüsü tarafından 1988 yılında yayınlanmıştır. Hastalıkları nükseden ve etmeyen olmak üzere iki sınıfa ayrılmış hastaların değerlendirme sonucunu içeren 9 kategorik özniteliğe sahip 286 veriden oluşmaktadır [126].

- Wisconsin meme kanseri : 1992 yılında Wisconsin Üniversitesi hastanesinde Dr. Wolberg tarafından toplanan orijinal Wisconsin meme kanseri veri kümesi 10 tamsayı öznitelik ve 2 sınıf ile tanımlanmış 699 örnek içermektedir. Özniteliklerden biri anonim sıra numarası olup diğer öznitelikler hasta ile ilgili klinik tahlil ve ölçüm bilgilerini kapsamaktadır. Hastaların tümör durumlarının iyi huylu (benign) ve habis (malignant) olması ile veriler iki sınıfa ayrılmıştır [126, 129].

- Yeni tiroid : Yeni tiroit veri kümesi Stefan Aeberhard tarafından 1992 yılında yayınlanmış tiroid bezinin çok çalışması (hipertiroid), az çalışması (hipotiroid) ve normal çalışması (ötiroid) olmak üzere 3 sınıfa ayrılmış ve 215 hasta kaydı içermektedir [126].

- Lenf grafisi : Lenf grafisi veri kümesinde normal, habis, metastaz ve fibrozis olmak üzere 4 sınıfa ayrılmış ve 18 öznitelik ile tanımlanmış 148 onkoloji hastası kaydı bulunmaktadır [126].

B - Sınıf Oranı Dengesiz Veri Kümeleri

Algoritmaların normal veri kümeleri karşısındaki başarısı karşılaştırıldıktan sonra, her bir sınıf için farklı oranda örnek barındıran veri kümeleri için gösterdiği performanslarını değerlendirmek amacıyla dengesiz veri kümeleri de kullanılmıştır. Tablo EK-1.2'de verilen bu problemler, mevcut UCI problemlerindeki sınıf sayılarının ikiye indirgenmesiyle elde edilmiştir. Tabloda sırasıyla veri kümesinin adı, örnek sayısı,

öznitelik sayısı, sınıf değeri sayısı, min-max sınıf isimleri ile her bir sınıfın örnek oranı verilmiştir.

- Cam: Cam veri kümesinde, 7 farklı cam türüne ait hammadde oranları ve üretim teknikleri bilgilerini içeren 214 kayıt vardır. Bu veri kümesinden Cam0, Cam1, Cam2, Cam4, Cam5, Cam6 ve Cam0123vs456 adıyla bir grup verinin pozitif kalan diğer verilerin negatif olarak işaretlendiği 7 farklı dengesiz veri kümesi elde edilmiştir [126].

- Ecoli: 8 öznitelik değeri içeren Ecoli verikümesinde 8 sınıfa ayrılmış 336 gram negatif bakteri kaydı bulunmaktadır. Bu veri kümesinden elde edilen Ecoli0vs1 dengesiz veri kümesi sadece *cp* ve *im* sınıfına ait 220 örnek içerir. Ecoli1, Ecoli2, Ecoli3, Ecoli4 dengesiz veri kümeleri ise sırasıyla *im*, *pp*, *imU* ve *Om* sınıfına ait örnekleri pozitif ve diğer örnekleri negatif olmak üzere iki sınıfa ayırmıştır [126].

- Maya: Maya veri kümesinde 8 özniteliği ile proteinlerin hücresel bölge yerleşimi hakkında bilgi içeren ve 10 ayrı sınıfa ayrılmış 1484 kayıt vardır. Maya1, Maya3, Maya4, Maya5, Maya6 adı verilen dengesiz veri kümeleri sırasıyla *Nuc*, *Me3*, *Me2*, *Me1* ve *Exc* sınıflarına ait örnekleri pozitif ve diğer örnekleri negatif işaretlemek suretiyle elde edilmiştir. Maya2vs8 verikümesi ise 2 sınıfa ait 482 örnek kullanılarak türetilmiştir [126].

- Haberman: 3 öznitelikle tanımlanmış Haberman'ın hastalarının ameliyat sonrası 5 yıl içinde sağ kalıp kalmadığını not ettiği veri kümesi 306 kayıt içermektedir. Hayatta kalan hasta oranı %73.58 olduğu için veri kümesi dengesiz sınıf dağılımına sahiptir [126].

- Segmentasyon: Resim segmentasyonu veri kümesi 7 farklı dış mekan fotoğrafından çıkartılan 3x3 piksel boyutunda 2308 adet bölgenin 19 öznitelik ile tanımlandığı kayıtlar içermektedir. Bölgeler tuğla, gökyüzü, yeşillik, beton, pencere, yol ve çimen olmak üzere 7 sınıfa ayrılmıştır. Segmentasyon0 tuğla resim bölge kayıtlarının pozitif ile diğer kayıtların negatif ile sınıflandırıldığı bir dengesiz dağılımlı veri kümesi olarak kullanılmıştır [126].

- Sayfa-Blokları: *yazı*, *yatay yazı*, *dikey yazı*, *resim* ve *grafik* olmak üzere 5 sınıfa ayrılmış toplam 5472 kayıt 54 belgeden alınan sayfa bloklarının 10 özellik ile

Tablo EK-1.2. Sınıf oranları dengesiz olan veri kümeleri.

Veri Kümesi	N	Top	|S|	Sınıf Değerleri (Min., Max.)	Sınıf Örnek Oranları (Min. - Max.)
Cam1	214	9	2	(Düz pencere cam; diğerleri)	%35,51 - %64,49
Ecoli0vs1	220	7	2	(Im; cp)	%35,00 - %65,00
Wisconsin Meme K.	683	9	2	(Malignant; benign)	%35,00 - %65,00
Diyabet	768	8	2	(Pozitif; negatif)	%34,84 - %66,16
Süsen0	150	4	2	(Iris-Setosa; diğerleri)	%33,33 - %66,67
Cam0	214	9	2	(Düz cam; diğerleri)	%32,71 - %67,29
Maya1	1484	8	2	(Nuc; diğerleri)	%28,91 - %71,09
Taşıtlar1	846	18	2	(Saab; diğerleri)	%28,37 - %71,63
Taşıtlar2	846	18	2	(Bus; diğerleri)	%28,37 - %71,63
Taşıtlar3	846	18	2	(Opel; diğerleri)	%28,37 - %71,63
Haberman	306	3	2	(Ölü; Sağlam)	%27,42 - %73,58
Cam0123vs456	214	9	2	(Pencere dışı camlar; diğerleri)	%23,83 - %76,17
Taşıtlar0	846	18	2	(Van; diğerleri)	%23,64 - %76,36
Ecoli1	336	7	2	(Im; diğerleri)	%22,92 - %77,08
Yeni Tiroit2	215	5	2	(Hipotiroit; diğerleri)	%16,89 - %83,11
Yeni Tiroit1	215	5	2	(Hipertiroit; diğerleri)	%16,28 - %83,72
Ecoli2	336	7	2	(Pp; diğerleri)	%15,48 - %84,52
Segmentasyon0	2308	19	2	(Tuğla; diğerleri)	%14,26 - %85,74
Cam6	214	9	2	(Masalambası; diğerleri)	%13,55 - %86,45
Maya3	1484	8	2	(Me3; diğerleri)	%10,98 - %89,02
Ecoli3	336	7	2	(ImU; diğerleri)	%10,88 - %89,12
Sayfa-Blokları0	5472	10	2	(Diğerleri; yazı)	%10,23 - %89,77
Vowel0	988	13	2	(Hid; diğerleri)	%9,01 - %90,99
Cam2	214	9	2	(Otocam; diğerleri)	%8,78 - %91,22
Ecoli4	336	7	2	(Om; diğerleri)	%6,74 - %93,26
Cam4	214	9	2	(Kavanoz; diğerleri)	%6,07 - %93,93
Abalone9vs18	731	8	2	(18; 9)	%5,65 - %94,25
Cam5	214	9	2	(Sofra takımı; diğerleri)	%4,20 - %95,80
Maya2vs8	482	8	2	(Pox; cyt)	%4,15 - %95,85
Maya4	1484	8	2	(Me2; diğerleri)	%3,43 - %96,57
Maya5	1484	8	2	(Me1; diğerleri)	%2,96 - %97,04
Maya6	1484	8	2	(Exc; diğerleri)	%2,49 - %97,51
Abalone19	4174	8	2	(19; diğerleri)	%0,77 - %99,23

tanımlanması ile elde edilmiştir [126].

- Vowel (Sesli harfler): Vowel veri kümesi, 13 öznitelik ile tanımlanmış ve 11 sınıfa ayrılmış 988 kayıt içerir. Vowel'dan türetilmiş Vowel0 adı ile deneylerde kullanılan veri kümesi, *Hid* sınıfına ait örneklerin pozitif diğer örneklerin negatif etiketlenmesi ile elde edilmiştir.

- Abalone (Deniz kulağı): 4174 örnek içeren Abalone veri kümesi, fiziksel ve mikroskopik ölçüm değerlerini içeren 8 öznitelik ile tanımlanan Deniz kulaklarının yaşının sınıf değeri olarak kullanılması ile elde edilmiştir. Abalone9vs18 ve Abalone19 olmak üzere iki dengesiz dağılımlı veri kümesi karşılaştırmalarda kullanılmıştır.

- Wisconsin Meme Kanseri: Wisconsin, Diyabet, Taşıtlar ve Süsen çiçeği veri kümeleri yukarıda bölümde açıklanmıştır. Wisconsin iki sınıfa ayrılan dengesiz dağılıma sahip örnekler içermekte olduğu için bu kısımdaki karşılaştırmalarda da kullanılmıştır.

Tablo EK-1.3. Led probleminin verilerini üretmek için kullanılan led doğruluk tablosu.

1. parça	2. parça	3. parça	4. parça	5. parça	6. parça	7. parça	Sınıfı (Gösterilen Rakam)
1	1	1	0	1	1	1	0
0	0	1	0	0	1	0	1
1	0	1	1	1	0	1	2
1	0	1	1	0	1	1	3
0	1	1	1	0	1	0	4
1	1	0	1	0	1	1	5
1	1	0	1	1	1	1	6
1	0	1	0	0	1	0	7
1	1	1	1	1	1	1	8
1	1	1	1	0	1	1	9

Tablo EK-1.4. Kullanılan test veri akışı problemleri.

Problem	Türü	Öznitelik sayısı	Sınıf	Gürültü	Toplam veri sayısı
Agrawal	Yapay	9	2	-	250.000
Led	Yapay	24	10	20%	250.000
Sea	Yapay	3	2	20%	250.000
Hyperplane	Yapay	10	2	-	250.000
RandomRBF	Yapay	10	2	-	250.000
RandomTree	Yapay	10	2	-	250.000
Airlines	Gerçek	7	2	-	539.383
CovType	Gerçek	54	7	-	581.012
Poker	Gerçek	10	10	-	829.201
Power	Gerçek	2	24	-	29.928

- Diyabet (Pima): Diyabet veri kümesi 8 öznitelik ile tanımlı 768 örnek içermekte olup iki sınıfa ayrılmıştır. Sınıflar %34,84-%66,16 olmak üzere farklı oranlarda ayrıldığı için kullanılmıştır.

- Taşıtlar: Taşıtlar veri kümesinden bir sınıfa ait örneklerin pozitif, diğerlerin negatif işaretlenmesi suretiyle Taşıtlar0, Taşıtlar1, Taşıtlar2, Taşıtlar3 dengesiz veri kümeleri türetilmiştir.

- Süsen Çiçeği: Süsen0, Iris-Setosa sınıfına ait örneklerin diğerlerinden ayrılarak iki sınıfa indirgendiği bir dengesiz dağılımlı veri kümesi olarak karşılaştırmalarda kullanılmıştır.

- Yeni Tiroit: Yeni Tiroit veri kümesi, 3 sınıfa ayrılmış 215 veri içermektedir. Yeni Tiroit1 ve Yeni Tiroit2 adı verilen dengesiz veri kümeleri, veri kümelerinde sırasıyla hipertiroit ve hipotiroit sınıfındaki örneklerin pozitif diğerlerinin negatif işaretlenmesi ile elde edilmiştir.

C - Veri Akışı Test Problemleri

- Agrawal: Deneylerde kullanılan Agrawal yapay problemi 6 sayısal 3 kategorik olmak üzere toplam 9 öznitelik ve 2 sınıf içeren karar özniteliğine sahiptir. Öznitelikler kişisel bilgiler içeren yıllık gelir miktarı, komisyon oranı, yaş, eğitim seviyesi, sahip olunan araç türü, zip posta kodu, evin değeri, tapu yıllık

  Agrawal veri kümesi 10 farklı fonksiyonda tanımlanmış giriş-çıkış bağıntısıyla öznitelik değerlerini karşılaştırıp sınıf kararı vermektedir. Deneylerde 250.000 veri rastgele üretilmiş ve kullanılmıştır. Veriler üretilirken öznitelik değerleri rastgele belirlenir, 10 fonksiyondan seçilen biri yardımı ile sınıfı belirlenir [130].

- Led : Yapay üretilen bir veri kümesi olan Led, elektronik cihazlarda 0'dan 9'a rakam gösterimi için kullanılan 7-parçalı göstergenin doğruluk tablosu (Tablo EK-1.3) temel alınarak ortaya konulmuştur. Gösterilen rakam verinin sınıfını, 7 led'in o anki durumu (açık/kapalı) ise giriş özniteliklerini ortaya koyar. Zorlaştırmak amacıyla veri kümesine 17 rastgele öznitelik değeri eklenmiş ve 7 gerçek öznitelik değerleri üzerine %20 oranında rastgele gürültü uygulanmıştır. Deneylerde kullanılan veri akışında rastgele 250.000 kayıt kullanılmıştır.

- Sea: Sea problemi yapay üretilen 3 giriş özniteliğin aldığı değer doğrultusunda 4 farklı fonksiyonda (Denklem EK-1.1) belirlenmiş bağıntı ile 2 sınıfa ayırmaktadır. Sayısal değer alabilen giriş özniteliklerinden ilk ikisi çıkış üzerinde etkili olurken üçüncü giriş özniteliği hiç bir şekilde çıkış sınıfına etki etmemektedir [119]. Deneyler 1. fonksiyon üzerinden türetilmiş 250.000 kayıt içeren veri akışı üzerinde gerçekleştirilmiştir.

$$
\begin{aligned}
1.Fonksiyon: \quad F_1(x,y) &= \begin{cases} x+y \leq 8 & ; \ Sınıf = 1 \\ Diğer \ durumlarda & ; \ Sınıf = 2 \end{cases} \\
2.Fonksiyon: \quad F_2(x,y) &= \begin{cases} x+y \leq 9 & ; \ Sınıf = 1 \\ Diğer \ durumlarda & ; \ Sınıf = 2 \end{cases} \\
3.Fonksiyon: \quad F_3(x,y) &= \begin{cases} x+y \leq 7 & ; \ Sınıf = 1 \\ Diğer \ durumlarda & ; \ Sınıf = 2 \end{cases} \\
4.Fonksiyon: \quad F_4(x,y) &= \begin{cases} x+y \leq 9,5 & ; \ Sınıf = 1 \\ Diğer \ durumlarda & ; \ Sınıf = 2 \end{cases}
\end{aligned}
\tag{EK-1.1}
$$

- Hyperplane: Döndürülen bir hiper-düzlem ile ilgili probleme ait yapay bir problemdir. Veriler reel sayı değeri alabilen 10 giriş özniteliğinin rastgele çarpanlar ile elde edilen

toplamına bakarak iki ayrı sınıfa ayrılmaktadır [85].

- RandomRBF: Radyal temel matematiksel fonksiyonuna dayalı rastgele 10 öznitelik değeri kullanarak veri üreten ve iki sınıfa ayıran yapay bir problemdir. Deneylerde 250.000 rastgele veri kullanılmıştır [85].

- RandomTree: 5 kategorik 5 sayısal olmak üzere 10 öznitelik değerlerini kontrol ederek rastgele üretilen bir karar ağacı barındırır. Karar ağacı verileri iki sınıfa ayırmaktadır. Deneylerde 250.000 rastgele veri kullanılmıştır [85].

- Airlines: Airlines sınıflandırma testinde kullanılan 2009 yılındaki Data Expo yarışmasında kullanılmış Ekim 1987 ile Nisan 2008 arasında gerçekleşmiş ABD sahasındaki ticari uçuşlara ait gerçek bir veri kümesidir. Veriler 3 sayısal 4 kategorik toplam 7 öznitelik ile tanımlı olup normal veya ertelenmiş uçuş olmak üzere 2 sınıfa ayrılmış biçimde 539.383 örnek barındırır [90].

- CovType: ABD Ormanları Kurumunun 2. Bölge RIS verisinden alınmış 30x30 metre birim alandaki 54 öznitelik ile tanımlanmış yüzeyin 7 farklı kaplama tipinden hangisi olduğunu içeren 581.012 örnekli gerçek bir veri kümesidir [126].

- Poker: 52 li standart kağıt destesinden alınmış 5 kartın durumunu 10 kategorik öznitelik ile tanımlanmış ve durumunu 10 farklı sınıfa ayıran 829.201 örnekli gerçek veri kümesidir [126].

- Power: 1995 1998 yılları arasında İtalyan Elektrik Şirketi tarafından ölçülmüş merkezi güç ağı ve diğer ağlardan saatlik alınan güç verilerini içermektedir. Verilerin hangi saat alındığı bilgisi tahmin amacıyla kullanılmış 29.928 veri 24 sınıfa ayrılmıştır [131].

EK-2

UCI Test Problemleri için Keşfedilen Kural Kümeleri

13 test probleminin herbiri için en yüksek test doğruluk değerine sahip ABCMiner ve CoABCMiner algoritmalarıyla keşfedilen kural kümeleri aşağıda verilmiştir.

Tablo EK-2.1. E.coli gen dizisi veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%88,42 Test:%90,91)

Sıra No	Kural Kümesi
1	IF Nucleotid_39 = g THEN Class $\approx$ Negative
2	ELSE IF Nucleotid_16 = t THEN Class $\approx$ Positive
3	ELSE IF Nucleotid_15 = a THEN Class $\approx$ Negative
4	ELSE IF Nucleotid_20 = c THEN Class $\approx$ Negative
5	ELSE IF Nucleotid_18 = a THEN Class $\approx$ Positive
6	Default Class: Negative

Tablo EK-2.2. E.coli gen dizisi veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%96,88 Test:%100,00)

Sıra No	Kural Kümesi
1	IF Nucleotid_15 $\neq$ [a,c] AND Nucleotid_17 = [g,t,c] AND Nucleotid_46 $\neq$ [a] AND Nucleotid_49 = [a,g,c] AND Nucleotid_52 = [a,t,c] THEN Class $\approx$ Positive
2	ELSE IF Nucleotid_16 = [g,t,c] AND Nucleotid_17 = [g] AND Nucleotid_18 = [a,t,c] THEN Class $\approx$ Positive
3	ELSE IF Nucleotid_15 = [a,g,c] THEN Class $\approx$ Negative
4	ELSE IF Nucleotid_16 = [a,g,c] THEN Class $\approx$ Negative
5	ELSE IF Nucleotid_10 $\neq$ [a] AND Nucleotid_14 $\neq$ [g] AND Nucleotid_42 $\neq$ [t] THEN Class $\approx$ Negative
6	Default Class: Positive

Tablo EK-2.3. Taşıtlar veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%71,75 Test:%63,53)

Sıra No	Kural Kümesi
1	IF Distancecircularity IN [40.0 , 80.603698] AND Maxlengthaspectratio IN [2.0 , 40.773948] AND Elongatedness IN [26.0 , 46.007452] AND Lengthrectangular IN [118.0 , 160.368557] AND Majorskewness IN [63.425258 , 116.392639] AND Minorskewness IN [0.0 , 10.647749] AND Minorkurtosis IN [0.0 , 27.768711] THEN Class = Bus
2	ELSE IF Compactness IN [87.567279 , 117.0] AND Circularity IN [35.579016 , 59.0] AND Radiusratio IN [166.528097 , 240.197316] AND Maxlengthaspectratio IN [6.115935 , 39.145431] AND Scatterratio IN [145.134992 , 262.0] AND Lengthrectangular IN [118.0 , 174.766971] AND Minorvariance IN [247.194854 , 720.714756] AND Gyrationradius IN [112.811011 , 241.557865] AND Majorskewness IN [59.0 , 74.760101] AND Majorkurtosis IN [180.329537 , 203.475944] AND Hollowsratio IN [194.454403 , 211.0] THEN Class = Saab
3	ELSE IF Radiusratio IN [162.620488 , 294.894897] AND Praxisaspectratio IN [47.0 , 78.738098] AND Maxlengthaspectratio IN [6.640956 , 50.639308] AND Majorvariance IN [174.439974 , 288.0] AND Hollowsratio IN [191.337222 , 211.0] THEN Class = Opel
4	ELSE IF Elongatedness IN [39.443649 , 59.140661] AND Lengthrectangular IN [136.642714 , 188.0] AND Majorskewness IN [61.597499 , 117.287844] AND Majorkurtosis IN [176.0 , 204.606164] THEN Class = Van
5	ELSE IF Compactness IN [77.712621 , 109.391734] AND Circularity IN [35.317542 , 59.0] AND Scatterratio IN [112.0 , 173.959201] AND Elongatedness IN [31.601847 , 53.799407] AND Gyrationradius IN [133.937037 , 268.0] AND Majorskewness IN [59.0 , 124.162285] AND Majorkurtosis IN [176.0 , 201.196664] THEN Class = Saab
6	ELSE IF Radiusratio IN [105.0 , 205.185285] AND Elongatedness IN [35.810640 , 58.656249] AND Praxisrectangular IN [17.225234 , 21.553660] AND Gyrationradius IN [125.401366 , 268.0] AND Majorskewness IN [59.0 , 120.204604] AND Minorkurtosis IN [0.0 , 36.622846] THEN Class = Opel
7	ELSE IF Circularity IN [41.260479 , 59.0] THEN Class = Bus
8	Default Class: Van

Tablo EK-2.4. Taşıtlar veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar (Eğitim:%69,38 Test:%75,29).

Sıra No	Kural Kümesi
1	IF Maxlengthaspectratio $\leq$ 7.035098 AND Elongatedness < 47.927324 AND Majorvariance $\geq$ 144.286005 AND Minorskewness < 11.989490 AND Minorkurtosis $\leq$ 27.003616 THEN Class $\approx$ Bus
2	ELSE IF Compactness $\geq$ 82.154283 AND Radiusratio < 178.020131 AND Praxisaspectratio < 68.827589 AND Lengthrectangular $\geq$ 126.044853 AND Majorvariance $\leq$ 180.108878 AND Minorvariance < 393.036484 AND Majorskewness $\geq$ 61.295053 AND Minorskewness $\leq$ 19.396460 AND Minorkurtosis < 19.862210 AND Hollowsratio $\geq$ 184.420356 THEN Class $\approx$ Van
3	ELSE IF Compactness > 84.336803 AND Radiusratio < 178.020131 AND Elongatedness > 40.085986 AND Lengthrectangular $\geq$ 127.811843 AND Majorvariance $\leq$ 181.032857 AND Minorvariance < 381.401642 AND Majorskewness $\leq$ 79.825581 AND Minorskewness < 19.786332 AND Minorkurtosis < 22.796257 THEN Class $\approx$ Van
4	ELSE IF Compactness > 82.971232 AND Circularity > 33.550843 AND Praxisaspectratio < 68.745641 AND Majorvariance $\leq$ 175.731765 AND Minorvariance < 381.401642 AND Majorskewness $\geq$ 61.295053 AND Minorskewness < 20.408943 AND Minorkurtosis < 27.372145 AND Majorkurtosis > 180.354295 THEN Class $\approx$ Van
5	ELSE IF Maxlengthaspectratio $\geq$ 7.415408 AND Scatterratio $\leq$ 167.946354 AND Lengthrectangular $\geq$ 126.527151 AND Majorvariance $\geq$ 130.640507 AND Minorvariance < 393.036484 AND Majorskewness $\geq$ 61.295053 AND Minorskewness $\leq$ 19.396460 AND Minorkurtosis $\leq$ 27.003616 AND Majorkurtosis $\geq$ 181.962119 THEN Class $\approx$ Van
6	ELSE IF Compactness > 82.971232 AND Scatterratio $\leq$ 174.633497 AND Praxisrectangular < 21.221085 AND Majorvariance $\leq$ 177.543354 AND Gyrationradius < 213.441368 AND Minorskewness $\leq$ 19.396460 AND Minorkurtosis < 37.442159 AND Hollowsratio < 210.911345 THEN Class $\approx$ Van

Tablo EK-2.4 – tablonun devamı.

Sıra No	Kural Kümesi
7	ELSE IF Compactness < 107.837052 AND Radiusratio ≤ 233.554355 AND Maxlengthaspectratio ≥ 6.192005 AND Elongatedness < 50.081626 AND Praxisrectangular ≤ 25.571471 AND Lengthrectangular ≥ 125.313989 AND Majorvariance < 276.954858 AND Minorvariance ≥ 390.230174 AND Majorskewness ≥ 62.565341 AND Minorskewness ≤ 15.420085 AND Minorkurtosis < 40.228623 AND Majorkurtosis < 199.881515 AND Hollowsratio ≥ 184.420356 THEN Class ≈ Opel
8	ELSE IF Compactness ≥ 84.870940 AND Radiusratio ≥ 152.005966 AND Praxisaspectratio < 67.726412 AND Lengthrectangular ≤ 169.619969 AND Majorvariance ≥ 176.692921 AND Gyrationradius < 240.075798 AND Majorskewness ≤ 73.624713 AND Majorkurtosis ≥ 183.544976 AND Hollowsratio ≥ 187.723815 THEN Class ≈ Saab
9	ELSE IF Circularity ≤ 58.545780 AND Radiusratio ≤ 279.378161 AND Maxlengthaspectratio > 7.860171 AND Praxisrectangular < 25.233446 AND Lengthrectangular < 177.592352 AND Majorvariance ≥ 177.418839 AND Gyrationradius > 124.683368 AND Majorskewness ≤ 74.783676 AND Hollowsratio > 186.919763 THEN Class ≈ Saab
10	ELSE IF Radiusratio ≤ 233.554355 AND Praxisaspectratio > 48.835446 AND Maxlengthaspectratio ≥ 7.135790 AND Praxisrectangular ≥ 18.833175 AND Lengthrectangular ≥ 127.811843 AND Majorvariance ≥ 184.637359 AND Minorvariance ≤ 787.349218 AND Gyrationradius ≥ 112.397679 AND Majorskewness ≤ 87.601237 AND Minorskewness < 18.180748 AND Minorkurtosis < 40.709868 THEN Class ≈ Opel
11	ELSE IF Circularity > 40.541240 AND Praxisrectangular ≥ 18.833175 AND Lengthrectangular > 131.794568 AND Minorskewness < 19.219660 AND Hollowsratio < 188.695559 THEN Class ≈ Bus
12	ELSE IF Compactness < 115.099001 AND Distancecircularity > 74.378481 AND Praxisaspectratio < 75.724694 AND Maxlengthaspectratio ≥ 7.259657 AND Scatterratio > 144.709713 AND Elongatedness ≤ 39.107509 AND Lengthrectangular ≥ 134.034490 AND Majorskewness ≥ 61.295053 AND Minorskewness ≤ 21.607190 AND Minorkurtosis < 40.709868 AND Majorkurtosis ≥ 183.544976 THEN Class ≈ Opel
13	ELSE IF Compactness < 108.329877 AND Distancecircularity ≥ 75.012812 AND Radiusratio ≤ 233.554355 AND Maxlengthaspectratio ≤ 27.741101 AND Scatterratio > 160.075691 AND Minorvariance ≥ 390.230174 AND Majorskewness ≥ 61.295053 AND Minorskewness < 20.058867 AND Minorkurtosis < 40.709868 AND Hollowsratio > 190.034029 THEN Class ≈ Opel
14	ELSE IF Compactness > 77.658186 AND Radiusratio < 311.599716 AND Scatterratio ≥ 141.258595 AND Elongatedness < 47.927324 AND Minorvariance ≤ 437.987134 AND Majorskewness ≥ 61.295053 AND Minorskewness ≤ 21.607190 AND Minorkurtosis < 23.550270 AND Hollowsratio < 210.911345 THEN Class ≈ Bus
15	ELSE IF Praxisaspectratio < 68.827589 AND Scatterratio ≥ 153.326505 AND Majorvariance IN [285.223431,285.223431] AND Minorvariance ≥ 330.471831 AND Majorskewness ≤ 87.601237 AND Majorkurtosis ≥ 184.721616 AND Hollowsratio > 189.711617 THEN Class ≈ Saab
16	ELSE IF Praxisaspectratio < 88.736472 AND Majorvariance > 181.964500 AND Majorskewness ≤ 79.825581 AND Majorkurtosis ≥ 183.544976 AND Hollowsratio > 190.034029 THEN Class ≈ Opel
17	ELSE IF Scatterratio ≥ 155.814558 AND Majorskewness ≤ 75.855137 AND Hollowsratio IN [209.944725,209.944725] THEN Class ≈ Opel
18	ELSE IF Compactness ≥ 89.957041 AND Distancecircularity ≥ 66.819732 AND Radiusratio < 229.998913 AND Praxisaspectratio < 70.116973 AND Maxlengthaspectratio < 13.108385 AND Elongatedness ≤ 44.466371 AND Minorvariance > 311.839052 AND Majorskewness ≤ 79.825581 AND Majorkurtosis ≥ 188.979623 THEN Class ≈ Saab
19	ELSE IF Compactness > 82.325190 AND Circularity < 57.964666 AND Radiusratio > 112.478675 AND Praxisaspectratio < 68.827589 AND Maxlengthaspectratio < 15.200010 AND Scatterratio ≤ 222.589754 AND Gyrationradius ≤ 226.619493 AND Minorkurtosis ≥ 15.998030 THEN Class ≈ Saab
20	ELSE IF Compactness IN [102.650887,102.650887] AND Circularity < 41.656070 AND Praxisaspectratio < 69.735455 AND Maxlengthaspectratio < 12.833570 AND Lengthrectangular < 136.951751 AND Minorvariance ≤ 502.470433 AND Gyrationradius ≥ 112.397679 AND Majorskewness < 86.885107 THEN Class ≈ Saab
21	ELSE IF Compactness ≤ 100.342489 AND Praxisaspectratio < 66.046173 AND Maxlengthaspectratio < 9.905067 AND Gyrationradius IN [191.191916,191.191916] AND Majorskewness ≤ 84.902660 AND Minorkurtosis ≥ 4.213747 AND Hollowsratio ≥ 183.599691 THEN Class ≈ Saab
22	ELSE IF Radiusratio ≤ 263.415046 AND Lengthrectangular ≤ 169.619969 AND Gyrationradius ≥ 183.697129 AND Minorskewness < 13.936906 THEN Class ≈ Bus
23	ELSE IF Circularity > 33.550843 AND Praxisaspectratio < 69.061359 AND Lengthrectangular < 136.951751 AND Majorskewness ≥ 61.295053 AND Minorskewness ≤ 21.607190 THEN Class ≈ Opel

Tablo EK-2.4 – tablonun devamı.

Sıra No	Kural Kümesi
24	ELSE IF Praxisaspectratio < 66.046173 AND Maxlengthaspectratio < 15.200010 AND Majorvariance < 223.262241 AND Gyrationradius $\leq$ 171.942675 AND Majorskewness $\geq$ 61.295053 AND Minorskewness $\leq$ 21.607190 AND Majorkurtosis < 198.731241 THEN Class $\approx$ Opel
25	ELSE IF Praxisaspectratio < 67.160334 AND Majorskewness $\geq$ 61.295053 AND Hollowsratio > 201.842332 THEN Class $\approx$ Opel
26	ELSE IF Gyrationradius < 180.188590 AND Minorskewness IN [16.038754,16.038754] AND Majorkurtosis $\leq$ 193.107128 AND Hollowsratio IN [197.964345,197.964345] THEN Class $\approx$ Opel
27	ELSE IF Maxlengthaspectratio $\leq$ 5.123892 AND Majorvariance < 268.088258 AND Minorvariance < 444.452664 THEN Class $\approx$ Saab
28	Default Class: Bus

Tablo EK-2.5. Soya fasülyesi veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%70,41 Test:%77,94)

Sıra No	Kural Kümesi
1	IF temp = norm AND leafspots-halo = no-yellow-halos AND leaf-malf = absent AND seed = norm THEN Class $\approx$ brown-spot
2	ELSE IF plant-growth = norm AND leafspots-halo = no-yellow-halos AND leaf-malf = absent AND lodging = yes AND external-decay = absent AND seed-size = norm THEN Class $\approx$ alternarialeaf-spot
3	ELSE IF leafspot-size = gt-1/8 AND mold-growth = absent THEN Class $\approx$ frog-eye-leaf-spot
4	ELSE IF leaves = abnorm AND canker-lesion = dk-brown-blk THEN Class $\approx$ phytophthora-rot
5	ELSE IF int-discolor = brown THEN Class $\approx$ brown-stem-rot
6	ELSE IF leafspots-marg = dna AND fruit-pods = diseased THEN Class $\approx$ anthracnose
7	ELSE IF fruiting-bodies = present AND shriveling = absent THEN Class $\approx$ diaporthe-stem-canker
8	ELSE IF leaves = abnorm AND leafspots-halo = absent AND canker-lesion = tan THEN Class $\approx$ charcoal-rot
9	ELSE IF stem-cankers = below-soil THEN Class $\approx$ rhizoctonia-root-rot
10	ELSE IF leaf-mild = upper-surf THEN Class $\approx$ powdery-mildew
11	ELSE IF leaf-mild = lower-surf THEN Class $\approx$ downy-mildew
12	ELSE IF leafspot-size = lt-1/8 AND lodging = yes AND fruit-pods = norm AND mold-growth = absent AND roots = norm THEN Class $\approx$ bacterial-blight
13	ELSE IF leafspot-size = lt-1/8 AND fruit-spots = absent THEN Class $\approx$ bacterial-pustule
14	ELSE IF canker-lesion = tan THEN Class $\approx$ purple-seed-stain
15	ELSE IF leafspot-size = gt-1/8 AND stem-cankers = absent AND roots = norm THEN Class $\approx$ phyllosticta-leaf-spot
16	ELSE IF leafspots-marg = dna AND stem = norm THEN Class $\approx$ 2-4-d-injury
17	Default Class: diaporthe-pod-&-stem-blight

Tablo EK-2.6. Soya fasülyesi veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%94,46 Test:%95,65).

Sıra No	Kural Kümesi
1	IF plant-stand ≠ [lt-normal] AND temp ≠ [gt-norm] AND area-damaged = [scattered,low-areas,whole-field] AND severity ≠ [minor] AND leaves ≠ [norm] AND leafspots-halo ≠ [yellow-halos] AND leafspot-size = [lt-1/8,dna] AND stem ≠ [norm] AND stem-cankers = [above-sec-nde] AND int-discolor ≠ [brown] AND fruit-pods ≠ [diseased,few-present] AND fruit-spots = [absent,brown-w/blk-specks,dna] AND seed = [norm] AND roots ≠ [galls-cysts] THEN Class ≈ diaporthe-stem-canker
2	ELSE IF precip ≠ [norm,gt-norm] AND area-damaged = [low-areas,upper-areas,whole-field] AND severity ≠ [severe] AND leafspots-halo = [absent,yellow-halos] AND leaf-mild = [absent,upper-surf] AND canker-lesion = [brown,dk-brown-blk,tan] AND fruiting-bodies = [absent] AND external-decay ≠ [firm-and-dry,watery] AND int-discolor = [black] AND seed = [norm] AND shriveling ≠ [present] AND roots = [norm] THEN Class ≈ charcoal-rot
3	ELSE IF precip = [norm,gt-norm] AND temp ≠ [gt-norm] AND area-damaged = [low-areas,whole-field] AND leafspots-marg = [no-w-s-marg,dna] AND leaf-mild = [absent,upper-surf] AND stem ≠ [norm] AND canker-lesion = [dna,brown] AND fruiting-bodies ≠ [present] AND fruit-spots = [absent,brown-w/blk-specks,distort,dna] AND mold-growth = [absent] AND seed-discolor ≠ [present] THEN Class ≈ rhizoctonia-root-rot
4	ELSE IF plant-stand = [lt-normal] AND precip = [norm,gt-norm] AND area-damaged = [low-areas,whole-field] AND leaves ≠ [norm] AND leafspot-size ≠ [gt-1/8] AND stem ≠ [norm] AND canker-lesion ≠ [brown,tan] AND int-discolor = [none] AND fruit-pods ≠ [diseased] AND fruit-spots = [absent,brown-w/blk-specks,distort,dna] THEN Class ≈ phytophthora-rot
5	ELSE IF precip ≠ [lt-norm] AND plant-growth = [norm] AND leafspot-size ≠ [lt-1/8,dna] AND leaf-shread ≠ [present] AND stem-cankers = [absent,below-soil,above-soil] AND canker-lesion ≠ [brown,dk-brown-blk] AND fruiting-bodies = [absent] AND int-discolor ≠ [brown] AND sclerotia = [absent] AND mold-growth = [present] AND shriveling ≠ [present] AND roots = [norm,galls-cysts] THEN Class ≈ downy-mildew
6	ELSE IF precip = [norm,gt-norm] AND temp = [norm,gt-norm] AND severity ≠ [severe] AND leafspots-marg = [w-s-marg,no-w-s-marg] AND leafspot-size ≠ [gt-1/8,dna] AND canker-lesion = [dna,dk-brown-blk] AND external-decay ≠ [firm-and-dry,watery] AND fruit-pods ≠ [diseased] AND seed = [norm] AND mold-growth = [absent] AND roots ≠ [rotted,galls-cysts] THEN Class ≈ bacterial-blight
7	ELSE IF precip = [norm,gt-norm] AND leaf-malf = [absent] AND canker-lesion = [tan] AND seed ≠ [norm] AND roots ≠ [rotted,galls-cysts] THEN Class ≈ purple-seed-stain
8	ELSE IF temp = [gt-norm] AND area-damaged ≠ [low-areas] AND seed-tmt = [none] AND leaves ≠ [abnorm] AND leaf-malf = [absent] AND canker-lesion = [dna,brown] AND mycelium = [absent] AND int -discolor ≠ [brown] THEN Class ≈ diaporthe-pod-&-stem-blight
9	ELSE IF precip ≠ [gt-norm] AND leaves ≠ [norm] AND leaf-malf = [absent] AND leaf-mild = [absent] AND fruit-pods = [norm,few-present] AND seed = [abnorm] AND shriveling ≠ [present] AND roots ≠ [norm] THEN Class ≈ cyst-nematode
10	ELSE IF leafspots-halo = [absent] AND leaf-shread = [absent] AND leaf-malf ≠ [absent] AND lodging = [yes] AND external-decay ≠ [firm-and-dry,watery] AND roots = [norm,galls-cysts] THEN Class ≈ 2-4-d-injury
11	ELSE IF plant-growth = [abnorm] AND leaf-malf = [present] AND stem = [abnorm] THEN Class ≈ herbicide-injury
12	ELSE IF leaf-shread = [absent] AND stem = [abnorm] AND stem-cankers ≠ [below-soil,above-soil] AND fruiting-bodies ≠ [present] AND external-decay = [absent,watery] AND sclerotia = [absent] AND fruit-pods ≠ [diseased,dna] AND seed-discolor = [absent] AND seed-size ≠ [lt-norm] AND roots ≠ [rotted] THEN Class ≈ brown-stem-rot
13	ELSE IF date ≠ [april,september,october] AND precip ≠ [gt-norm] AND severity ≠ [severe] AND leafspots-halo ≠ [absent,yellow-halos] AND leafspots-marg = [w-s-marg,dna] AND leafspot-size ≠ [lt-1/8,dna] AND leaf-mild = [absent,lower-surf] AND stem-cankers = [absent,below-soil,above-soil] AND canker-lesion ≠ [brown,tan] AND fruit-spots = [absent,brown-w/blk-specks] AND seed = [norm] AND shriveling = [absent] AND roots = [norm] THEN Class ≈ phyllosticta-leaf-spot
14	ELSE IF leafspot-size = [lt-1/8] AND stem ≠ [abnorm] AND fruit-pods = [norm,dna] THEN Class ≈ bacterial-pustule
15	ELSE IF leafspot-size = [lt-1/8,dna] AND leaf-shread = [absent] AND stem-cankers ≠ [absent,above-soil] AND mycelium = [absent] AND fruit-spots = [absent,colored,brown-w/blk-specks,distort] AND roots = [norm] THEN Class ≈ anthracnose

Tablo EK-2.6 – tablonun devamı.

Sıra No	Kural Kümesi
16	ELSE IF date = [august,september,october] AND precip = [norm,gt-norm] AND temp ≠ [lt-norm] AND plant-growth = [norm] AND leaves ≠ [norm] AND leafspots-halo ≠ [yellow-halos] AND leafspots-marg = [w-s-marg] AND leafspot-size = [gt-1/8,dna] AND leaf-malf ≠ [present] AND leaf-mild = [absent,upper-surf] AND stem-cankers ≠ [below-soil,above-soil,above-sec-nde] AND external-decay = [absent,watery] AND int-discolor ≠ [brown] AND mold-growth = [absent] AND roots ≠ [rotted,galls-cysts] THEN Class ≈ alternarialeaf-spot
17	ELSE IF date ≠ [april,july] AND precip ≠ [gt-norm] AND leaf-shread = [absent] AND stem ≠ [abnorm] AND external-decay = [absent] AND fruit-pods = [norm] THEN Class ≈ powdery-mildew
18	ELSE IF precip = [norm,gt-norm] AND temp ≠ [lt-norm] AND area-damaged = [low-areas,upper-areas,whole-field] AND severity = [pot-severe,severe] AND leafspots-halo ≠ [absent,yellow-halos] AND leafspot-size = [gt-1/8] AND leaf-malf ≠ [present] AND lodging = [yes] AND stem-cankers ≠ [below-soil,above-soil] AND int-discolor = [none] AND fruit-spots ≠ [colored,distort] AND seed ≠ [abnorm] AND seed-discolor = [absent] AND seed-size = [norm] AND roots ≠ [rotted,galls-cysts] THEN Class ≈ brown-spot
19	ELSE IF date ≠ [october] AND precip = [norm,gt-norm] AND crop-hist ≠ [diff-lst-year] AND leafspots-halo ≠ [absent,yellow-halos] AND leafspot-size = [gt-1/8,dna] AND leaf-malf ≠ [present] AND lodging ≠ [no] AND stem-cankers ≠ [below-soil,above-soil] AND external-decay = [absent] AND int-discolor = [none,brown] AND fruit-spots = [absent,colored,brown-w/blk-specks,distort] AND seed = [norm] AND shriveling ≠ [present] AND roots = [norm] THEN Class ≈ brown-spot
20	ELSE IF date ≠ [october] AND precip ≠ [lt-norm] AND temp ≠ [lt-norm] AND leaves = [abnorm] AND leafspots-marg = [w-s-marg] AND leafspot-size = [gt-1/8,dna] AND lodging = [yes] AND stem-cankers = [absent,above-sec-nde] AND sclerotia ≠ [present] AND fruit-pods = [norm] AND mold-growth = [absent] AND seed-discolor = [absent] AND roots ≠ [rotted,galls-cysts] THEN Class ≈ brown-spot
21	ELSE IF temp = [norm,gt-norm] AND leafspots-halo ≠ [absent,yellow-halos] AND leaf-shread ≠ [present] AND leaf-malf = [absent] AND leaf-mild = [absent] AND stem-cankers ≠ [absent] AND canker-lesion ≠ [tan] AND fruiting-bodies = [absent] AND int-discolor = [none] AND fruit-spots = [absent,colored,brown-w/blk-specks,distort] AND seed = [norm] AND seed-discolor = [absent] THEN Class ≈ frog-eye-leaf-spot
22	ELSE IF severity ≠ [severe] AND plant-growth = [norm] AND leafspots-halo ≠ [absent,yellow-halos] AND leafspots-marg ≠ [no-w-s-marg] AND fruit-pods ≠ [norm,few-present] AND mold-growth = [absent] AND seed-discolor = [absent] THEN Class ≈ frog-eye-leaf-spot
23	ELSE IF precip = [norm,gt-norm] AND hail = [yes] AND crop-hist = [same-lst-two-yrs,same-lst-sev-yrs] AND leaves = [abnorm] AND leafspot-size = [gt-1/8,dna] AND leaf-malf = [absent] AND lodging = [yes] AND stem-cankers ≠ [above-soil] AND fruit-pods ≠ [norm,few-present,dna] AND mold-growth ≠ [present] AND roots = [norm] THEN Class ≈ frog-eye-leaf-spot
24	ELSE IF date ≠ [may,june,september] AND leafspots-halo ≠ [absent,yellow-halos] AND leaf-malf = [absent] AND lodging = [yes] THEN Class ≈ frog-eye-leaf-spot
25	ELSE IF leaves = [abnorm] AND stem = [abnorm] AND external-decay = [firm-and-dry] AND fruit-pods ≠ [few-present,dna] AND fruit-spots = [absent,brown-w/blk-specks,distort,dna] THEN Class ≈ anthracnose
26	ELSE IF date = [may,july,october] AND area-damaged = [low-areas,upper-areas,whole-field] AND seed-tmt = [none,fungicide] AND germination = [lt-80] AND leafspot-size ≠ [lt-1/8,gt-1/8] AND leaf-mild = [upper-surf,lower-surf] AND stem-cankers ≠ [below-soil,above-soil,above-sec-nde] AND fruit-pods = [norm,diseased] AND fruit-spots = [absent,colored,brown-w/blk-specks,distort] THEN Class ≈ powdery-mildew
27	Default Class: brown-spot

Tablo EK-2.7. Hayvanat bahçesi veri kümesi için ABCMiner ile keşfedilen kurallar (Eğitim:%93,41 Test:%100,00).

Sıra No	Kural Kümesi
1	IF Milk = 1 THEN Class ≈ 1
2	ELSE IF Feathers = 1 THEN Class ≈ 2
3	ELSE IF Fins = 1 THEN Class ≈ 4
4	ELSE IF Airborne = 0 AND Backbone = 0 THEN Class ≈ 7
5	ELSE IF Backbone = 0 THEN Class ≈ 6

Tablo EK-2.7 – tablonun devamı.

Sıra No	Kural Kümesi
6	Default Class: 3

Tablo EK-2.8. Hayvanat bahçesi için CoABC-Miner ile keşfedilen kurallar (Eğitim:%100,00 Test:%100,00).

Sıra No	Kural Kümesi
1	IF Milk $\neq$ [0] THEN Class $\approx$ 1
2	ELSE IF Hair = [0] AND Feathers = [1] THEN Class $\approx$ 2
3	ELSE IF Airborne $\neq$ [1] AND Toothed $\neq$ [0] AND Breathes $\neq$ [1] AND Fins = [1] THEN Class $\approx$ 4
4	ELSE IF Milk = [0] AND Airborne $\neq$ [1] AND Aquatic = [1] AND Toothed = [1] AND Breathes = [1] AND Fins $\neq$ [1] THEN Class $\approx$ 5
5	ELSE IF Backbone = [0] AND Breathes = [1] AND Legs $\neq$ [0,4,8] THEN Class $\approx$ 6
6	ELSE IF Feathers $\neq$ [1] AND Milk $\neq$ [1] AND Backbone = [1] AND Fins $\neq$ [1] AND Tail $\neq$ [0] THEN Class $\approx$ 3
7	ELSE IF Airborne = [0] AND Backbone $\neq$ [1] THEN Class $\approx$ 7
8	Default Class: 1

Tablo EK-2.9. Mantar veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%97,32 Test:%97,04)

Sıra No	Kural Kümesi
1	IF odor = 'n' AND gill-size = 'b' THEN Class $\approx$ 'e'
2	ELSE IF bruises? = 'f' AND stalk-root = 'b' THEN Class $\approx$ 'p'
3	ELSE IF gill-size = 'b' AND stalk-shape = 'e' AND stalk-surface-above-ring = 's' THEN Class $\approx$ 'e'
4	ELSE IF bruises? = 't' AND gill-spacing = 'c' THEN Class $\approx$ 'p'
5	Default Class: 'e'

Tablo EK-2.10. Mantar veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%99,89 Test:%100,00)

Sıra No	Kural Kümesi
1	IF odor $\neq$ ['a','l','m','n'] THEN Class $\approx$ 'p'
2	ELSE IF odor = ['a','c','l','n','s','y'] AND gill-size $\neq$ ['n'] AND spore-print-color = ['b','k','n','u','w','y'] THEN Class $\approx$ 'e'
3	ELSE IF cap-surface $\neq$ ['g'] AND odor $\neq$ ['f','m','p'] AND gill-size $\neq$ ['n'] AND ring-type = ['e','f','p','s'] AND spore-print-color $\neq$ ['b','h','r','u','y'] THEN Class $\approx$ 'e'

Tablo EK-2.10 – tablonun devamı.

Sıra No	Kural Kümesi
4	ELSE IF odor = ['a','l','m','n','s'] AND stalk-color-above-ring = ['c','g','o','p','w','y'] AND ring-number = ['n','o'] AND spore-print-color = ['b','h','k','n','r','u','y'] THEN Class ≈ 'e'
5	ELSE IF bruises? = ['f'] AND gill-spacing = ['c','d'] AND stalk-root = ['b','e','u','z'] AND stalk-color-above-ring ≠ ['c','e','g','o'] AND veil-color = ['n','w'] AND ring-type ≠ ['f'] AND spore-print-color = ['b','h','k','n','r','u','w','y'] AND population ≠ ['a','c','n'] AND habitat ≠ ['m','u'] THEN Class ≈ 'p'
6	ELSE IF gill-spacing = ['c','d'] AND stalk-surface-below-ring = ['k','s','y'] AND ring-number = ['n','o'] AND ring-type ≠ ['c','p','s','z'] AND spore-print-color ≠ ['b','k','u'] THEN Class ≈ 'p'
7	ELSE IF odor = ['a','c','f','n','p','s','y'] AND gill-spacing = ['c'] AND stalk-root = ['b','u'] AND stalk-color-below-ring = ['b','n','p','w','y'] AND veil-type = ['p'] THEN Class ≈ 'p'
8	ELSE IF stalk-surface-above-ring ≠ ['k'] AND stalk-surface-below-ring ≠ ['f','k','y'] AND veil-type = ['p'] AND veil-color = ['o','w'] THEN Class ≈ 'e'
9	ELSE IF cap-shape = ['c','f','s','x'] AND gill-size = ['n'] AND stalk-color-below-ring = ['c','e','p','w','y'] THEN Class ≈ 'p'
10	ELSE IF gill-spacing ≠ ['c','d'] AND gill-color = ['b','e','g','h','k','n','p','r','w'] AND stalk-color-above-ring ≠ ['b','g','y'] THEN Class ≈ 'e'
11	ELSE IF ring-number ≠ ['n'] AND spore-print-color ≠ ['b','h','r','u','y'] THEN Class ≈ 'p'
12	Default Class: 'e'

Tablo EK-2.11. Monkun problemi 2 veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%96,91 Test:%100,00)

Sıra No	Kural Kümesi
1	IF a2 IN [1.0 , 2.145335] AND a5 IN [1.0 , 2.680097] THEN Class ≈ 1
2	Default Class: 0

Tablo EK-2.12. Monkun problemi 2 veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%96,95 Test:%100,00)

Sıra No	Kural Kümesi
1	IF a2 ≥ 2.809352 THEN Class ≈ 0
2	ELSE IF a5 < 3.246333 THEN Class ≈ 1
3	ELSE IF a5 > 2.076414 THEN Class ≈ 0
4	Default Class: 1

Tablo EK-2.13. Süsen çiçeği veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%97,78 Test:%100,00)

Sıra No	Kural Kümesi
1	IF petalLength IN [1.0 , 2.281114] THEN Class ≈ Iris-setosa
2	ELSE IF petalLength IN [1.0 , 4.843762] AND petalWidth IN [0.328995 , 1.191230] THEN Class ≈ Iris-versicolor
3	Default Class: Iris-virginica

Tablo EK-2.14. Süsen çiçeği veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%96,30 Test:%100,00)

Sıra No	Kural Kümesi
1	IF petalWidth < 0.930583 THEN Class ≈ Iris-setosa
2	ELSE IF sepalLength < 7.089239 AND petalLength ≥ 2.118168 AND petalWidth < 1.703769 THEN Class ≈ Iris-versicolor
3	ELSE IF petalLength ≥ 4.869249 THEN Class ≈ Iris-virginica
4	ELSE IF petalWidth ≥ 1.651212 THEN Class ≈ Iris-virginica
5	Default Class: Iris-setosa

Tablo EK-2.15. Diyabet veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%81,77 Test:%76,62)

Sıra No	Kural Kümesi
1	IF preg IN [0.0 , 6.391255] AND plas IN [0.0 , 156.028446] AND mass IN [0.0 , 43.023563] AND pedi IN [0.078 , 0.796731] AND age IN [21.0 , 34.606721] THEN Class ≈ tested_negative
2	ELSE IF plas IN [98.583113 , 199.0] AND skin IN [0.0 , 57.895122] AND insu IN [0.0 , 649.402655] AND mass IN [25.148509 , 67.1] AND pedi IN [0.169330 , 2.42] AND age IN [21.0 , 53.784855] THEN Class ≈ tested_positive
3	ELSE IF plas IN [12.336344 , 199.0] AND skin IN [0.0 , 59.825589] AND insu IN [0.0 , 256.309739] AND mass IN [3.803271 , 48.121566] AND pedi IN [0.151905 , 2.42] AND age IN [32.124950 , 81.0] THEN Class ≈ tested_negative
4	ELSE IF preg IN [0.0 , 7.825605] AND mass IN [17.479190 , 40.630092] AND pedi IN [0.078 , 0.885949] AND age IN [22.835577 , 81.0] THEN Class ≈ tested_positive
5	Default Class: tested_negative

Tablo EK-2.16. Diyabet veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%79,45 Test:%83,12)

Sıra No	Kural Kümesi
1	IF preg < 6.493741 AND plas < 130.336133 AND mass < 44.709840 AND pedi < 0.849723 THEN Class ≈ tested_negative
2	ELSE IF preg ≤ 6.513271 AND plas ≤ 129.290240 AND insu ≤ 568.043044 AND mass < 45.327550 AND pedi < 0.854322 THEN Class ≈ tested_negative
3	ELSE IF preg < 6.844306 AND plas ≤ 127.315723 AND pres ≤ 122.0 AND mass < 45.365165 AND pedi < 2.245118 AND age < 39.804777 THEN Class ≈ tested_negative
4	ELSE IF preg < 7.926014 AND plas < 127.742641 AND insu < 489.300798 AND mass ≤ 45.457230 AND pedi < 1.022831 THEN Class ≈ tested_negative
5	ELSE IF preg < 13.275055 AND plas ≤ 123.979149 AND insu < 424.339999 AND mass < 45.351869 AND pedi < 0.849723 THEN Class ≈ tested_negative
6	ELSE IF preg < 9.683950 AND plas ≤ 126.056304 AND pres < 99.561922 AND insu ≤ 526.883982 AND mass < 45.347677 AND pedi < 0.849723 THEN Class ≈ tested_negative
7	ELSE IF preg < 6.238704 AND plas ≤ 157.242075 AND pres ≥ 0.680005 AND insu ≤ 526.883982 AND mass < 45.365165 AND pedi < 1.217807 AND age < 42.498453 THEN Class ≈ tested_negative
8	ELSE IF plas ≥ 123.009072 AND insu ≤ 601.585181 AND mass ≥ 27.890496 AND pedi > 0.078 AND age < 70.753509 THEN Class ≈ tested_positive
9	ELSE IF plas ≥ 123.679104 AND insu ≤ 601.585181 AND mass ≥ 27.451617 THEN Class ≈ tested_positive
10	ELSE IF plas ≥ 123.818725 AND insu ≤ 639.038283 AND mass > 23.698576 AND age > 21.0 THEN Class ≈ tested_positive
11	ELSE IF plas ≥ 123.071632 AND insu ≤ 639.038283 AND mass > 23.189808 AND age < 81.0 THEN Class ≈ tested_positive
12	ELSE IF plas ≥ 114.213899 AND insu ≤ 601.585181 AND mass ≥ 27.890496 THEN Class ≈ tested_positive
13	ELSE IF plas ≥ 107.735913 AND mass ≥ 27.890496 AND age ≥ 23.817668 THEN Class ≈ tested_positive
14	ELSE IF plas ≥ 123.961791 AND age ≥ 23.817668 THEN Class ≈ tested_positive
15	ELSE IF preg < 7.926014 AND plas < 155.607112 AND skin IN [56.135286,56.135286] AND insu ≤ 632.761185 AND mass < 45.347677 THEN Class ≈ tested_negative
16	ELSE IF preg < 7.445589 AND plas ≥ 0.0 AND pres < 99.561922 AND insu ≤ 568.043044 AND mass < 45.327550 AND pedi < 0.425680 THEN Class ≈ tested_negative
17	ELSE IF insu ≤ 626.237431 AND mass > 32.608938 THEN Class ≈ tested_positive
18	ELSE IF preg IN [8.987258,8.987258] AND insu ≤ 100.054358 THEN Class ≈ tested_negative
19	ELSE IF preg ≥ 5.506527 AND mass ≥ 27.451617 AND age ≤ 74.811541 THEN Class ≈ tested_positive
20	ELSE IF preg IN [13.859320,13.859320] AND insu ≤ 493.374667 THEN Class ≈ tested_positive
21	ELSE IF plas ≤ 147.845210 AND mass ≤ 25.982888 THEN Class ≈ tested_negative
22	ELSE IF insu ≤ 639.038283 AND mass < 45.351869 AND pedi ≤ 0.217279 THEN Class ≈ tested_negative
23	ELSE IF pres ≤ 112.072184 AND skin < 46.875104 AND insu ≤ 639.038283 AND pedi ≥ 0.257486 THEN Class ≈ tested_positive
24	ELSE IF preg < 14.021541 AND insu ≤ 375.000341 AND pedi < 0.849723 THEN Class ≈ tested_negative
25	ELSE IF mass IN [52.147644,52.147644] THEN Class ≈ tested_negative
26	ELSE IF pres ≥ 34.669140 AND mass ≥ 39.639443 THEN Class ≈ tested_negative
27	ELSE IF age < 53.367642 THEN Class ≈ tested_positive
28	ELSE IF pedi IN [2.322662,2.322662] THEN Class ≈ tested_negative
29	Default Class: tested_negative

Tablo EK-2.17. Hepatit veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%92,86 Test:%100,00)

Sıra No	Kural Kümesi
1	IF Age IN [7.0 , 60.579660] AND Spiders = No AND Ascites = No AND Varices = No AND Bilirubin IN [0.0 , 2.664873] AND Alk_Phosphate IN [0.0 , 217.453727] THEN Class ≈ Live
2	ELSE IF Ascites = No AND Alk_Phosphate IN [69.034052 , 295.0] AND Sgot IN [0.0 , 499.755443] AND Albumin IN [0.884724 , 5.303031] THEN Class ≈ Live
3	ELSE IF Age IN [24.694894 , 58.919635] AND Albumin IN [0.0 , 3.616638] AND Protime IN [0.0 , 42.648927] THEN Class ≈ Die
4	ELSE IF Bilirubin IN [0.0 , 3.804656] AND Sgot IN [30.411665 , 465.485426] AND Protime IN [0.0 , 67.524364] THEN Class ≈ Live
5	Default Class: Die

Tablo EK-2.18. Hepatit veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%91,37 Test:%100,00)

Sıra No	Kural Kümesi
1	IF Spiders = [No] AND Ascites ≠ [Yes] AND Varices ≠ [Yes] AND Bilirubin ≤ 6.903267 AND Alk_Phosphate < 231.546435 AND Sgot < 427.901155 THEN Class ≈ Live
2	ELSE IF Age > 28.554851 AND Sex ≠ [Male] AND Fatigue ≠ [No] AND Sgot < 586.203901 AND Albumin < 4.239739 AND Protime ≤ 50.087621 THEN Class ≈ Die
3	ELSE IF Spiders = [No] AND Ascites = [No] AND Varices ≠ [Yes] AND Bilirubin < 7.149926 AND Alk_Phosphate < 180.182500 THEN Class ≈ Live
4	ELSE IF Spleen_Palpable = [No] AND Varices ≠ [Yes] AND Bilirubin ≤ 2.670007 AND Alk_Phosphate < 232.840387 AND Sgot ≤ 523.030452 AND Albumin ≥ 2.562341 THEN Class ≈ Live
5	ELSE IF Spleen_Palpable ≠ [Yes] AND Varices ≠ [Yes] AND Bilirubin > 0.509998 AND Alk_Phosphate ≤ 242.560724 AND Albumin ≥ 2.889211 THEN Class ≈ Live
6	ELSE IF Malaise ≠ [Yes] AND Anorexia = [No] AND Ascites = [No] AND Varices ≠ [Yes] AND Alk_Phosphate < 242.442782 AND Sgot < 493.670679 THEN Class ≈ Live
7	ELSE IF Age > 23.454404 AND Sex = [Female] AND Spiders ≠ [No] AND Alk_Phosphate < 179.672635 AND Sgot ≤ 627.036347 AND Albumin < 4.299632 AND Protime ≤ 81.001979 THEN Class ≈ Die
8	ELSE IF Malaise ≠ [Yes] AND Ascites = [No] AND Alk_Phosphate ≤ 242.560724 AND Albumin ≥ 2.615537 THEN Class ≈ Live
9	ELSE IF Steroid = [Yes] AND Ascites ≠ [Yes] THEN Class ≈ Live
10	ELSE IF Age ≥ 26.462588 AND Steroid = [No] AND Antivirals = [No] AND Spiders ≠ [Yes] AND Varices = [No] AND Sgot < 637.404441 AND Histology = [Yes] THEN Class ≈ Die
11	ELSE IF Antivirals = [No] AND Alk_Phosphate > 159.903393 THEN Class ≈ Live
12	Default Class: Live

Tablo EK-2.19. Meme kanseri veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%79,12 Test:%82,14)

Sıra No	Kural Kümesi
1	IF Inv-nodes = 0-2 AND Irradiated = no THEN Class ≈ no-recurrence-events
2	ELSE IF Deg-malig = 2 THEN Class ≈ no-recurrence-events
3	ELSE IF Breast = left THEN Class ≈ recurrence-events
4	ELSE IF Age = 30-39 AND Irradiated = yes THEN Class ≈ no-recurrence-events
5	Default Class: recurrence-events

Tablo EK-2.20. Meme kanseri veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%79,92 Test:%89,29)

Sıra No	Kural Kümesi
1	IF Tumor-size = [0-4,5-9,10-14,15-19,20-24,25-29,30-34,35-39,40-44,50-54,55-59] AND Inv-nodes = [0-2,6-8,12-14,15-17,18-20,24-26,27-29,36-39] AND Deg-malig ≠ [3] THEN Class ≈ no-recurrence-events
2	ELSE IF Tumor-size = [0-4,5-9,10-14,15-19,20-24,25-29,30-34,35-39,40-44,50-54,55-59] AND Inv-nodes ≠ [9-11,21-23,27-29,33-35] AND Node-caps = [no] AND Deg-malig ≠ [3] THEN Class ≈ no-recurrence events
3	ELSE IF Inv-nodes = [0-2,6-8,9-11,15-17,18-20,21-23,30-32,36-39] AND Node-caps ≠ [yes] AND Breast-quad ≠ [right_up] AND Irradiated = [no] THEN Class ≈ no-recurrence-events
4	ELSE IF Age = [10-19,20-29,30-39,40-49,50-59,60-69] AND Menopause ≠ [lt40] AND Tumor-size = [0-4,5-9,10-14,15-19,20-24,25-29,30-34,35-39,40-44,50-54,55-59] AND Deg-malig = [3] THEN Class ≈ recurrence-events
5	ELSE IF Tumor-size = [0-4,5-9,10-14,15-19,20-24,25-29,30-34,35-39,40-44,50-54,55-59] AND Inv-nodes = [0-2,9-11,15-17,18-20,27-29] AND Deg-malig ≠ [3] AND Breast-quad ≠ [left_up] THEN Class ≈ no-recurrence-events
6	ELSE IF Age ≠ [10-19,20-29,30-39,60-69,70-79,90-99] AND Deg-malig ≠ [3] AND Breast-quad ≠ [right_up] THEN Class ≈ no-recurrence-events
7	ELSE IF Age ≠ [10-19,70-79] AND Tumor-size = [0-4,5-9,10-14,15-19,20-24,25-29,30-34,35-39,40-44,50-54,55-59] AND Inv-nodes = [3-5,6-8,9-11,12-14,15-17,27-29,30-32,36-39] THEN Class ≈ recurrence-events
8	ELSE IF Deg-malig = [2] AND Breast-quad ≠ [right_up] THEN Class ≈ no-recurrence-events
9	ELSE IF Age ≠ [10-19,70-79] AND Menopause ≠ [lt40] AND Deg-malig ≠ [1] AND Breast ≠ [right] AND Breast-quad ≠ [central] THEN Class ≈ recurrence-events
10	ELSE IF Menopause = [premeno] AND Tumor-size = [0-4,15-19,20-24,25-29,30-34,40-44,50-54] AND Breast-quad = [left_up,left_low,right_up] THEN Class ≈ recurrence-events
11	ELSE IF Age = [10-19,20-29,30-39,40-49,50-59,60-69] AND Tumor-size = [0-4,5-9,15-19,20-24,25-29,30-34,35-39,40-44,55-59] AND Inv-nodes ≠ [9-11,21-23,27-29,33-35] AND Deg-malig ≠ [1] AND Breast-quad ≠ [left_up,right_low] THEN Class ≈ recurrence-events
12	ELSE IF Menopause ≠ [premeno] AND Irradiated = [no] THEN Class ≈ no-recurrence-events
13	ELSE IF Age ≠ [10-19,30-39,50-59,60-69,70-79,80-89] AND Inv-nodes = [0-2,3-5,6-8,21-23,27-29,33-35] THEN Class ≈ no-recurrence-events
14	ELSE IF Tumor-size ≠ [5-9,10-14,15-19,25-29,30-34,35-39,40-44,50-54,55-59] AND Inv-nodes ≠ [6-8,9-11,33-35,36-39] AND Breast-quad = [left_up,left_low,right_up,central] THEN Class ≈ recurrence-events
15	Default Class: no-recurrence-events

Tablo EK-2.21. Wisconsin meme kanseri veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%96,82 Test:%100,00)

Sıra No	Kural Kümesi
1	IF clumpThickness IN [1.0 , 6.329143] AND cellSize IN [1.0 , 4.332628] AND bareNuclei IN [0.0 , 6.101997] AND normalNucleoli IN [1.0 , 7.813702] THEN Class $\approx$ 2
2	Default Class: 4

Tablo EK-2.22. Wisconsin meme kanseri veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%98,25 Test:%98,57)

Sıra No	Kural Kümesi
1	IF clumpThickness < 6.508518 AND cellShape $\leq$ 8.834888 AND marginalAdhesion < 9.615665 AND epithelialSize < 8.492429 AND bareNuclei $\leq$ 5.952006 AND blandChromatin $\leq$ 8.651982 AND normalNucleoli < 10.0 AND mitoses $\leq$ 9.984944 THEN Class $\approx$ 2
2	ELSE IF clumpThickness $\leq$ 9.952001 AND cellSize < 4.813137 AND cellShape $\leq$ 7.752345 AND epithelialSize < 5.970177 AND bareNuclei $\leq$ 7.196113 AND normalNucleoli < 2.731517 AND mitoses $\leq$ 5.186347 THEN Class $\approx$ 2
3	ELSE IF clumpThickness < 6.588058 AND marginalAdhesion $\leq$ 5.289092 AND epithelialSize < 5.481868 AND blandChromatin < 3.481619 AND normalNucleoli < 4.113193 THEN Class $\approx$ 2
4	ELSE IF cellSize $\geq$ 1.330490 AND cellShape $\geq$ 2.910208 AND blandChromatin > 1.0 THEN Class $\approx$ 4
5	ELSE IF cellSize $\geq$ 1.987634 AND cellShape $\geq$ 1.263678 AND epithelialSize > 1.822061 AND blandChromatin > 2.702804 THEN Class $\approx$ 4
6	ELSE IF clumpThickness $\geq$ 1.288659 AND cellSize $\geq$ 1.330490 AND cellShape $\geq$ 1.263678 AND epithelialSize $\geq$ 1.311358 THEN Class $\approx$ 4
7	ELSE IF cellShape $\geq$ 1.263678 AND normalNucleoli > 2.562127 THEN Class $\approx$ 4
8	ELSE IF bareNuclei $\geq$ 5.979725 THEN Class $\approx$ 4
9	ELSE IF marginalAdhesion > 2.276465 THEN Class $\approx$ 4
10	ELSE IF bareNuclei IN [7.038454,7.038454] THEN Class $\approx$ 2
11	ELSE IF mitoses IN [2.041295,2.041295] THEN Class $\approx$ 2
12	ELSE IF epithelialSize IN [7.684320,7.684320] THEN Class $\approx$ 2
13	Default Class: 2

Tablo EK-2.23. Yeni tiroid veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%97,93 Test:%100,00)

Sıra No	Kural Kümesi
1	IF T3resin IN [95.096263 , 144.0] AND thyroxin IN [5.210563 , 12.459199] AND TSH_value IN [-0.7 , 8.809714] THEN Class $\approx$ normal
2	ELSE IF thyroxin IN [9.203457 , 25.3] AND triiodothyronine IN [1.420071 , 10.0] THEN Class $\approx$ hyper
3	ELSE IF thyroxin IN [0.5 , 6.565991] AND TSH_value IN [2.308801 , 56.3] THEN Class $\approx$ hypo

Tablo EK-2.23 – tablonun devamı.

Sıra No	Kural Kümesi
4	Default Class: normal

Tablo EK-2.24. Yeni tiroid veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%97,42 Test:%100,00)

Sıra No	Kural Kümesi
1	IF thyroxin $\geq$ 10.793260 AND triiodothyronine $\geq$ 1.534487 AND TSH_value < 0.796805 THEN Class $\approx$ hyper
2	ELSE IF thyroxin $\geq$ 5.395955 AND triiodothyronine $\leq$ 3.153055 AND thyroidstimulating < 4.095159 AND TSH_value $\geq$ 0.489326 THEN Class $\approx$ normal
3	ELSE IF T3resin > 66.307757 AND thyroxin $\leq$ 7.087381 AND TSH_value > 2.162031 THEN Class $\approx$ hypo
4	ELSE IF T3resin > 96.628507 AND thyroxin $\leq$ 14.232982 AND triiodothyronine < 2.945890 AND thyroidstimulating < 4.160806 AND TSH_value < 9.307368 THEN Class $\approx$ normal
5	ELSE IF thyroxin $\leq$ 6.116089 AND triiodothyronine $\leq$ 2.630878 AND TSH_value $\geq$ 1.209067 THEN Class $\approx$ hypo
6	Default Class: normal

Tablo EK-2.25. Lenf grafisi veri kümesi için ABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%84,21 Test:%93,33)

Sıra No	Kural Kümesi
1	IF lym_nodes_enlar IN [1.0 , 2.560915] AND changes_in_node = lac_margin THEN Class $\approx$ metastases
2	ELSE IF lym_nodes_dimin IN [1.0 , 1.485794] AND special_forms = vesicles AND no_of_nodes_in IN [1.194622 , 7.579277] THEN Class $\approx$ malign_lymph
3	ELSE IF changes_in_node = lacunar AND no_of_nodes_in IN [1.0 , 3.441466] THEN Class $\approx$ metastases
4	ELSE IF regeneration_of = no AND changes_in_lym = oval THEN Class $\approx$ malign_lymph
5	Default Class: metastases

Tablo EK-2.26. Lenf grafisi veri kümesi için CoABCMiner algoritmasıyla keşfedilen kurallar.(Eğitim:%92,48 Test:%93,33)

Sıra No	Kural Kümesi
1	IF bl_of_lymph_s = [no] AND lym_nodes_enlar $\leq$ 3.153141 AND defect_in_node $\neq$ [lacunar,lac_margin,lac_central] AND changes_in_stru $\neq$ [drop_like,coarse,stripped,faint] THEN Class $\approx$ normal
2	ELSE IF lymphatics $\neq$ [displaced] AND regeneration_of $\neq$ [no] AND lym_nodes_enlar $\leq$ 3.196690 AND changes_in_lym = [bean,oval] AND special_forms = [no,vesicles] THEN Class $\approx$ fibrosis

Tablo EK-2.26 – tablonun devamı.

Sıra No	Kural Kümesi
3	ELSE IF early_uptake_in $\neq$ [no] AND lym_nodes_dimin $<$ 2.552903 AND changes_in_node = [no,lacunar,lac_central] AND exclusion_of_no = [yes] THEN Class $\approx$ malign_lymph
4	ELSE IF block_of_affere = [yes] AND regeneration_of = [no] AND lym_nodes_enlar $\leq$ 3.153141 AND changes_in_node $\neq$ [no,lac_central] THEN Class $\approx$ metastases
5	ELSE IF lym_nodes_dimin $\leq$ 1.049125 AND changes_in_lym = [oval,round] AND changes_in_node = [lacunar,lac_central] AND exclusion_of_no = [yes] THEN Class $\approx$ malign_lymph
6	ELSE IF block_of_affere = [yes] AND lym_nodes_enlar $<$ 3.580145 AND changes_in_node = [lac_margin,lac_central] AND no_of_nodes_in $\leq$ 5.152996 THEN Class $\approx$ metastases
7	ELSE IF block_of_affere = [no] AND early_uptake_in $\neq$ [no] AND defect_in_node $\neq$ [no] AND changes_in_node = [lacunar,lac_margin,lac_central] AND special_forms $\neq$ [no] THEN Class $\approx$ malign_lymph
8	ELSE IF early_uptake_in $\neq$ [no] AND lym_nodes_dimin $\leq$ 2.658004 AND special_forms $\neq$ [no,chalices] AND no_of_nodes_in $\geq$ 2.467340 THEN Class $\approx$ malign_lymph
9	ELSE IF lym_nodes_enlar $\leq$ 3.306272 AND defect_in_node = [lacunar,lac_margin,lac_central] AND changes_in_node $\neq$ [no] AND no_of_nodes_in $\leq$ 2.594917 THEN Class $\approx$ metastases
10	ELSE IF block_of_affere = [no] AND changes_in_lym = [oval,round] THEN Class $\approx$ malign_lymph
11	ELSE IF early_uptake_in $\neq$ [yes] AND lym_nodes_dimin $\leq$ 2.774929 AND no_of_nodes_in $<$ 5.066881 THEN Class $\approx$ metastases
12	ELSE IF changes_in_node $\neq$ [lacunar,lac_central] AND changes_in_stru $\neq$ [no,grainy,drop_like,reticular,faint] THEN Class $\approx$ metastases
13	ELSE IF changes_in_lym $\neq$ [round] AND defect_in_node $\neq$ [no,lac_margin] AND no_of_nodes_in $<$ 4.509607 THEN Class $\approx$ malign_lymph
14	Default Class: metastases

EK-3

Gerçekleştirilen Deneylerde Elde Edilen Sonuçlar

Tablo EK-3.1'deki kısaltmalar şu şekildedir:

- Problem: Kullanılan veri kümesi.
- Algoritma: Kural keşfi için kullanılan algoritma.
- Pop. No: Algoritmada kullanılan rastgele üretilmiş başlangıç popülasyonu sıra numarası.
- Ç. Doğ. No.: 10 Kat çapraz doğrulama için kullanılan test verisi sıra numarası.
- Top. İşl. Say.: Meta-sezgisel algoritmanın popülasyondaki çözümleri toplam değerlendirme sayısı.
- Eğ. Doğr.: Eğitim sonunda keşfedilen sınıflandırma modelinin eğitim verilerini doğru sınıflandırma oranı.
- Test. Doğr.: Eğitim sonunda keşfedilen sınıflandırma modelinin test verilerini doğru sınıflandırma oranı.
- Eğ.-Test Değş. Oranı: Eğitim ile test doğruluğu arasındaki fark.
- Kur. Sa.: Algoritma tarafından keşfedilen kural sayısı.
- Koş. Sa.: Kural kümesindeki toplam koşul sayısı.
- Oran: Kural başına düşen ortalama koşul sayısı .
- Süre (sn): Algoritmanın sınıflandırma modelini öğrenmesi için geçen toplam süre.

Tablo EK-3.1. Deney sonuçları.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. İşl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. Sa.	Koş. Sa.	Oran	Süre (sn)
Diyabet	ABCMiner	1	0	80.482	%79,45	%59,74	%19,7	5	15	3	49,6
Diyabet	ABCMiner	1	1	80.655	%81,48	%62,34	%19,1	5	21	4,2	48,3
Diyabet	ABCMiner	1	2	80.528	%80,75	%63,64	%17,1	5	17	3,4	51,1
Diyabet	ABCMiner	1	3	80.488	%81,33	%67,53	%13,8	5	19	3,8	49,1
Diyabet	ABCMiner	1	4	100.643	%79,88	%66,23	%13,7	6	22	3,7	53,2
Diyabet	ABCMiner	1	5	80.515	%80,61	%74,03	%6,6	5	18	3,6	49,8

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Diyabet	ABCMiner	1	6	80.406	%78,44	%57,14	%21,3	5	15	3	48,9
Diyabet	ABCMiner	1	7	100.599	%81,04	%61,04	%20	6	20	3,3	52,7
Diyabet	ABCMiner	1	8	80.570	%80,20	%69,74	%10,5	5	21	4,2	46,7
Diyabet	ABCMiner	1	9	80.471	%82,66	%73,68	%9	5	16	3,2	49,1
Diyabet	ABCMiner	2	0	100.600	%80,46	%66,23	%14,2	6	21	3,5	52,2
Diyabet	ABCMiner	2	1	80.580	%79,16	%66,23	%12,9	5	20	4	50,5
Diyabet	ABCMiner	2	2	100.606	%79,59	%64,94	%14,7	6	16	2,7	52,3
Diyabet	ABCMiner	2	3	80.434	%79,31	%53,25	%26,1	5	16	3,2	48,9
Diyabet	ABCMiner	2	4	80.491	%79,88	%54,55	%25,3	5	18	3,6	50,7
Diyabet	ABCMiner	2	5	80.588	%79,74	%72,73	%7	5	19	3,8	48,4
Diyabet	ABCMiner	2	6	100.630	%80,03	%63,64	%16,4	6	22	3,7	52,6
Diyabet	ABCMiner	2	7	80.624	%81,77	%76,62	%5,1	5	21	4,2	51,3
Diyabet	ABCMiner	2	8	80.618	%82,51	%65,79	%16,7	5	21	4,2	48,7
Diyabet	ABCMiner	2	9	80.559	%78,90	%65,79	%13,1	5	21	4,2	48,4
Diyabet	ABCMiner	3	0	80.492	%80,03	%61,04	%19	5	17	3,4	48
Diyabet	ABCMiner	3	1	100.754	%82,06	%61,04	%21	6	23	3,8	53,9
Diyabet	ABCMiner	3	2	80.546	%81,19	%64,94	%16,3	5	19	3,8	49,1
Diyabet	ABCMiner	3	3	80.514	%81,04	%68,83	%12,2	5	17	3,4	48,1
Diyabet	ABCMiner	3	4	100.640	%79,02	%63,64	%15,4	6	23	3,8	56,5
Diyabet	ABCMiner	3	5	80.513	%79,45	%70,13	%9,3	5	16	3,2	47,8
Diyabet	ABCMiner	3	6	100.711	%81,77	%70,13	%11,6	6	23	3,8	52,5
Diyabet	ABCMiner	3	7	80.470	%80,61	%70,13	%10,5	5	17	3,4	48,4
Diyabet	ABCMiner	3	8	80.537	%79,77	%65,79	%14	5	21	4,2	49,4
Diyabet	ABCMiner	3	9	100.581	%80,78	%63,16	%17,6	6	18	3	49,7
Diyabet	ABCMiner	4	0	100.517	%80,90	%62,34	%18,6	6	15	2,5	41,2
Diyabet	ABCMiner	4	1	80.484	%82,92	%71,43	%11,5	5	18	3,6	39,1
Diyabet	ABCMiner	4	2	100.536	%79,45	%67,53	%11,9	6	15	2,5	42,4
Diyabet	ABCMiner	4	3	80.395	%79,16	%62,34	%16,8	5	16	3,2	39,6
Diyabet	ABCMiner	4	4	80.577	%79,74	%55,84	%23,9	5	18	3,6	39,1
Diyabet	ABCMiner	4	5	80.453	%80,75	%75,32	%5,4	5	16	3,2	39,1
Diyabet	ABCMiner	4	6	100.610	%80,46	%59,74	%20,7	6	19	3,2	42,2
Diyabet	ABCMiner	4	7	80.510	%79,16	%71,43	%7,7	5	20	4	39,3
Diyabet	ABCMiner	4	8	80.475	%79,34	%72,37	%7	5	15	3	39,4
Diyabet	ABCMiner	4	9	80.475	%80,64	%71,05	%9,6	5	17	3,4	39,6
Diyabet	ABCMiner	5	0	100.645	%81,91	%63,64	%18,3	6	20	3,3	41
Diyabet	ABCMiner	5	1	80.525	%79,74	%72,73	%7	5	17	3,4	37,1
Diyabet	ABCMiner	5	2	80.471	%79,59	%70,13	%9,5	5	18	3,6	40,4
Diyabet	ABCMiner	5	3	100.563	%81,62	%67,53	%14,1	6	17	2,8	42,2
Diyabet	ABCMiner	5	4	100.547	%80,03	%62,34	%17,7	6	16	2,7	42,5
Diyabet	ABCMiner	5	5	80.605	%81,19	%63,64	%17,6	5	20	4	39,6
Diyabet	ABCMiner	5	6	100.588	%79,88	%63,64	%16,2	6	16	2,7	43,4
Diyabet	ABCMiner	5	7	80.616	%81,91	%64,94	%17	5	21	4,2	41,1
Diyabet	ABCMiner	5	8	80.504	%79,05	%67,11	%11,9	5	15	3	39,1
Diyabet	ABCMiner	5	9	80.495	%81,21	%69,74	%11,5	5	17	3,4	40,9
Diyabet	C4.5	-	1	-	%80,46	%68,83	%11,6	7	10	1,4	0,6
Diyabet	C4.5	-	2	-	%74,10	%64,94	%9,2	6	8	1,3	0,6
Diyabet	C4.5	-	3	-	%79,74	%68,83	%10,9	13	19	1,5	0,6
Diyabet	C4.5	-	4	-	%77,86	%74,03	%3,8	10	15	1,5	0,6
Diyabet	C4.5	-	5	-	%78,87	%79,22	-0,3%	8	14	1,8	0,6
Diyabet	C4.5	-	6	-	%71,20	%72,73	-1,5%	7	8	1,1	0,6
Diyabet	C4.5	-	7	-	%76,70	%71,43	%5,3	8	14	1,8	0,6
Diyabet	C4.5	-	8	-	%78,44	%71,43	%7	6	8	1,3	0,6
Diyabet	C4.5	-	9	-	%78,32	%72,37	%6	10	18	1,8	0,6
Diyabet	C4.5	-	10	-	%80,64	%73,68	%7	12	19	1,6	0,6
Diyabet	CoABCMiner	1	0	110.476	%80,32	%74,03	%6,3	35	135	3,9	5,1
Diyabet	CoABCMiner	1	1	110.467	%80,75	%74,03	%6,7	32	135	4,2	5,1
Diyabet	CoABCMiner	1	2	110.468	%80,03	%74,03	%6	28	111	4	5
Diyabet	CoABCMiner	1	3	110.458	%80,03	%79,22	%0,8	32	113	3,5	5,3
Diyabet	CoABCMiner	1	4	110.481	%79,59	%83,12	-3,5%	37	150	4,1	5
Diyabet	CoABCMiner	1	5	110.460	%80,17	%79,22	%1	32	128	4	5,2
Diyabet	CoABCMiner	1	6	110.483	%78,00	%68,83	%9,2	26	93	3,6	4,9
Diyabet	CoABCMiner	1	7	110.476	%79,16	%72,73	6	110.469	%79,311		
Diyabet	CoABCMiner	1	8	110.467	%80,35	%82,89	-2,5%	36	163	4,5	5
Diyabet	CoABCMiner	1	9	110.447	%80,35	%67,11	%13,2	26	101	3,9	5,2
Diyabet	CoABCMiner	2	0	110.495	%80,61	%71,43	%9,2	31	119	3,8	4,9
Diyabet	CoABCMiner	2	1	110.474	%80,46	%71,43	%9	29	115	4	5,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Diyabet	CoABCMiner	2	2	110.473	%80,61	%76,62	%4	30	127	4,2	5,3
Diyabet	CoABCMiner	2	3	110.455	%80,46	%76,62	%3,8	30	130	4,3	5,4
Diyabet	CoABCMiner	2	4	110.493	%79,45	%83,12	-3,7%	28	99	3,5	5
Diyabet	CoABCMiner	2	5	110.434	%80,17	%81,82	-1,6%	27	113	4,2	5,2
Diyabet	CoABCMiner	2	6	110.477	%79,31	%70,13	%9,2	31	134	4,3	5,1
Diyabet	CoABCMiner	2	7	110.455	%78,00	%72,73	%5,3	31	128	4,1	5,1
Diyabet	CoABCMiner	2	8	110.441	%80,64	%81,58	-0,9%	32	131	4,1	5
Diyabet	CoABCMiner	2	9	110.471	%80,92	%68,42	%12,5	33	137	4,2	5,2
Diyabet	CoABCMiner	3	0	110.459	%81,19	%71,43	%9,8	25	108	4,3	5,2
Diyabet	CoABCMiner	3	1	110.450	%80,75	%77,92	%2,8	33	126	3,8	4,9
Diyabet	CoABCMiner	3	2	110.461	%80,46	%76,62	%3,8	27	113	4,2	5,1
Diyabet	CoABCMiner	3	3	110.467	%79,88	%71,43	%8,5	33	157	4,8	5,2
Diyabet	CoABCMiner	3	4	110.471	%79,74	%83,12	-3,4%	32	117	3,7	5,3
Diyabet	CoABCMiner	3	5	110.478	%79,45	%79,22	%0,2	32	143	4,5	5,1
Diyabet	CoABCMiner	3	6	110.469	%79,31	%74,03	%5,3	31	142	4,6	5,5
Diyabet	CoABCMiner	3	7	110.459	%78,73	%79,22	-0,5%	29	111	3,8	5,3
Diyabet	CoABCMiner	3	8	110.440	%80,49	%80,26	%0,2	26	112	4,3	5,5
Diyabet	CoABCMiner	3	9	110.452	%81,21	%71,05	%10,2	31	120	3,9	5,5
Diyabet	CoABCMiner	4	0	110.504	%80,75	%72,73	%8	26	88	3,4	4,9
Diyabet	CoABCMiner	4	1	110.470	%80,03	%75,32	%4,7	34	132	3,9	4,9
Diyabet	CoABCMiner	4	2	110.461	%80,32	%74,03	%6,3	26	96	3,7	5,1
Diyabet	CoABCMiner	4	3	110.453	%80,32	%75,32	%5	29	109	3,8	5,1
Diyabet	CoABCMiner	4	4	110.473	%80,17	%79,22	%1	31	121	3,9	5,3
Diyabet	CoABCMiner	4	5	110.455	%79,16	%80,52	-1,4%	30	120	4	5,2
Diyabet	CoABCMiner	4	6	110.473	%79,16	%74,03	%5,1	28	128	4,6	5,4
Diyabet	CoABCMiner	4	7	110.461	%78,87	%72,73	%6,1	29	124	4,3	5,4
Diyabet	CoABCMiner	4	8	110.470	%80,20	%80,26	-0,1%	29	139	4,8	5,7
Diyabet	CoABCMiner	4	9	110.458	%80,78	%68,42	%12,4	30	129	4,3	5,3
Diyabet	CoABCMiner	5	0	110.494	%80,61	%67,53	%13,1	26	87	3,3	4,9
Diyabet	CoABCMiner	5	1	110.468	%80,32	%74,03	%6,3	31	118	3,8	5
Diyabet	CoABCMiner	5	2	110.470	%79,45	%77,92	%1,5	29	130	4,5	5,2
Diyabet	CoABCMiner	5	3	110.453	%79,74	%75,32	%4,4	29	125	4,3	5,4
Diyabet	CoABCMiner	5	4	110.468	%79,45	%83,12	-3,7%	35	161	4,6	5,3
Diyabet	CoABCMiner	5	5	110.446	%79,88	%80,52	-0,6%	31	121	3,9	5,1
Diyabet	CoABCMiner	5	6	110.482	%79,45	%74,03	%5,4	30	119	4	5,2
Diyabet	CoABCMiner	5	7	110.443	%79,02	%72,73	%6,3	30	123	4,1	5,4
Diyabet	CoABCMiner	5	8	110.452	%80,78	%77,63	%3,1	27	115	4,3	5,4
Diyabet	CoABCMiner	5	9	110.476	%80,78	%69,74	%11	32	129	4	5,2
Diyabet	CORE	1	0	-	%78,29	%74,03	%4,3	12	32	2,7	89,8
Diyabet	CORE	1	1	-	%79,74	%68,83	%10,9	11	32	2,9	99,1
Diyabet	CORE	1	2	-	%79,31	%75,32	%4	6	20	3,3	98,6
Diyabet	CORE	1	3	-	%79,16	%77,92	%1,2	5	15	3	92,8
Diyabet	CORE	1	4	-	%77,86	%79,22	-1,4%	5	11	2,2	93,4
Diyabet	CORE	1	5	-	%78,58	%76,62	%2	10	27	2,7	91,7
Diyabet	CORE	1	6	-	%78,87	%72,73	%6,1	13	23	1,8	85,9
Diyabet	CORE	1	7	-	%78,73	%77,92	%0,8	6	17	2,8	96,2
Diyabet	CORE	1	8	-	%78,90	%76,32	%2,6	12	38	3,2	96,1
Diyabet	CORE	1	9	-	%79,62	%67,11	%12,5	8	20	2,5	91
Diyabet	CORE	2	0	-	%80,90	%70,13	%10,8	13	36	2,8	93,2
Diyabet	CORE	2	1	-	%78,87	%74,03	%4,8	14	40	2,9	101
Diyabet	CORE	2	2	-	%78,87	%74,03	%4,8	6	13	2,2	91,4
Diyabet	CORE	2	3	-	%79,59	%74,03	%5,6	12	30	2,5	94,6
Diyabet	CORE	2	4	-	%78,29	%71,43	%6,9	7	15	2,1	92,7
Diyabet	CORE	2	5	-	%78,73	%76,62	%2,1	12	21	1,8	91,4
Diyabet	CORE	2	6	-	%79,31	%70,13	%9,2	11	38	3,5	90
Diyabet	CORE	2	7	-	%78,87	%79,22	-0,3%	10	21	2,1	94,6
Diyabet	CORE	2	8	-	%79,05	%73,68	%5,4	13	28	2,2	91,4
Diyabet	CORE	2	9	-	%79,19	%67,11	%12,1	11	33	3	96,3
Diyabet	CORE	3	0	-	%79,74	%72,73	%7	7	15	2,1	92,9
Diyabet	CORE	3	1	-	%79,59	%72,73	%6,9	12	26	2,2	95,5
Diyabet	CORE	3	2	-	%78,73	%74,03	%4,7	8	15	1,9	92,9
Diyabet	CORE	3	3	-	%78,15	%75,32	%2,8	8	21	2,6	91,3
Diyabet	CORE	3	4	-	%78,15	%74,03	%4,1	8	24	3	90,7
Diyabet	CORE	3	5	-	%78,44	%76,62	%1,8	6	17	2,8	90,4
Diyabet	CORE	3	6	-	%78,58	%72,73	%5,9	10	21	2,1	87,4
Diyabet	CORE	3	7	-	%78,58	%72,73	%5,9	8	24	3	94,6

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Diyabet	CORE	3	8	-	%78,03	%84,21	-6,2%	8	19	2,4	92
Diyabet	CORE	3	9	-	%79,48	%69,74	%9,7	7	20	2,9	91,8
Diyabet	CORE	4	0	-	%78,87	%71,43	%7,4	12	35	2,9	91,8
Diyabet	CORE	4	1	-	%79,59	%76,62	%3	10	29	2,9	96
Diyabet	CORE	4	2	-	%78,73	%74,03	%4,7	10	27	2,7	94,6
Diyabet	CORE	4	3	-	%79,59	%66,23	%13,4	13	43	3,3	88,8
Diyabet	CORE	4	4	-	%78,00	%79,22	-1,2%	6	14	2,3	94
Diyabet	CORE	4	5	-	%78,15	%75,32	%2,8	10	28	2,8	87,7
Diyabet	CORE	4	6	-	%78,73	%72,73	%6	6	17	2,8	95,4
Diyabet	CORE	4	7	-	%77,86	%76,62	%1,2	8	23	2,9	106,7
Diyabet	CORE	4	8	-	%78,61	%76,32	%2,3	11	23	2,1	89,7
Diyabet	CORE	4	9	-	%79,34	%71,05	%8,3	8	24	3	91
Diyabet	CORE	5	0	-	%78,58	%75,32	%3,3	7	18	2,6	91
Diyabet	CORE	5	1	-	%78,58	%68,83	%9,8	4	10	2,5	91,9
Diyabet	CORE	5	2	-	%79,45	%77,92	%1,5	12	33	2,8	96,2
Diyabet	CORE	5	3	-	%78,44	%77,92	%0,5	8	21	2,6	90,5
Diyabet	CORE	5	4	-	%78,00	%81,82	-3,8%	6	15	2,5	97,2
Diyabet	CORE	5	5	-	%78,73	%72,73	%6	14	39	2,8	93,9
Diyabet	CORE	5	6	-	%78,87	%74,03	%4,8	9	23	2,6	97,4
Diyabet	CORE	5	7	-	%78,29	%80,52	-2,2%	7	16	2,3	90,2
Diyabet	CORE	5	8	-	%78,18	%81,58	-3,4%	10	31	3,1	95,6
Diyabet	CORE	5	9	-	%78,61	%67,11	%11,5	11	34	3,1	94
Diyabet	HIDER	1	0	-	%75,30	%72,70	%2,6	7	51	7,3	6
Diyabet	HIDER	1	1	-	%74,40	%72,70	%1,7	8	60	7,5	7
Diyabet	HIDER	1	2	-	%74,70	%76,60	-1,9%	9	66	7,3	7
Diyabet	HIDER	1	3	-	%76,40	%64,90	%11,5	12	90	7,5	8
Diyabet	HIDER	1	4	-	%73,80	%74,00	-0,2%	7	50	7,1	6
Diyabet	HIDER	1	5	-	%74,70	%76,60	-1,9%	9	68	7,6	7
Diyabet	HIDER	1	6	-	%76,30	%63,60	%12,7	12	89	7,4	8
Diyabet	HIDER	1	7	-	%74,70	%77,90	-3,2%	12	90	7,5	8
Diyabet	HIDER	1	8	-	%75,60	%76,30	-0,7%	11	81	7,4	8
Diyabet	HIDER	1	9	-	%74,60	%65,80	%8,8	7	53	7,6	6
Diyabet	HIDER	2	0	-	%75,00	%70,10	%4,9	11	81	7,4	6
Diyabet	HIDER	2	1	-	%74,50	%70,10	%4,4	12	90	7,5	7
Diyabet	HIDER	2	2	-	%75,10	%75,30	-0,2%	9	68	7,6	7
Diyabet	HIDER	2	3	-	%76,60	%71,40	%5,2	12	93	7,8	8
Diyabet	HIDER	2	4	-	%74,80	%77,90	-3,1%	12	89	7,4	6
Diyabet	HIDER	2	5	-	%74,20	%72,70	%1,5	9	68	7,6	7
Diyabet	HIDER	2	6	-	%75,10	%70,10	%5	8	60	7,5	8
Diyabet	HIDER	2	7	-	%75,10	%72,70	%2,4	8	58	7,3	8
Diyabet	HIDER	2	8	-	%76,60	%69,70	%6,9	12	90	7,5	8
Diyabet	HIDER	2	9	-	%76,40	%68,40	%8	11	83	7,5	6
Diyabet	HIDER	3	0	-	%75,40	%63,60	%11,8	9	65	7,2	6
Diyabet	HIDER	3	1	-	%77,30	%70,10	%7,2	12	87	7,3	7
Diyabet	HIDER	3	2	-	%74,10	%71,40	%2,7	9	63	7	7
Diyabet	HIDER	3	3	-	%75,10	%67,50	%7,6	10	72	7,2	8
Diyabet	HIDER	3	4	-	%76,00	%80,50	-4,5%	9	63	7	6
Diyabet	HIDER	3	5	-	%74,40	%70,10	%4,3	8	59	7,4	7
Diyabet	HIDER	3	6	-	%74,80	%67,50	%7,3	7	52	7,4	8
Diyabet	HIDER	3	7	-	%73,50	%75,30	-1,8%	7	49	7	8
Diyabet	HIDER	3	8	-	%75,00	%68,40	%6,6	9	69	7,7	8
Diyabet	HIDER	3	9	-	%75,30	%69,70	%5,6	10	70	7	6
Diyabet	HIDER	4	0	-	%75,50	%72,70	%2,8	10	73	7,3	6
Diyabet	HIDER	4	1	-	%74,80	%70,10	%4,7	11	80	7,3	7
Diyabet	HIDER	4	2	-	%74,80	%77,90	-3,1%	10	73	7,3	7
Diyabet	HIDER	4	3	-	%78,10	%67,50	%10,6	12	89	7,4	8
Diyabet	HIDER	4	4	-	%76,10	%72,70	%3,4	9	67	7,4	6
Diyabet	HIDER	4	5	-	%72,60	%74,00	-1,4%	6	42	7	7
Diyabet	HIDER	4	6	-	%75,40	%63,60	%11,8	12	89	7,4	8
Diyabet	HIDER	4	7	-	%75,30	%75,30	%0	10	73	7,3	8
Diyabet	HIDER	4	8	-	%76,00	%67,10	%8,9	10	78	7,8	8
Diyabet	HIDER	4	9	-	%74,60	%64,50	%10,1	9	69	7,7	6
Diyabet	HIDER	5	0	-	%76,30	%64,90	%11,4	11	84	7,6	6
Diyabet	HIDER	5	1	-	%74,50	%70,10	%4,4	7	57	8,1	7
Diyabet	HIDER	5	2	-	%75,00	%71,40	%3,6	11	76	6,9	7
Diyabet	HIDER	5	3	-	%76,70	%67,50	%9,2	9	65	7,2	8

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Diyabet	HIDER	5	4	-	%75,70	%75,30	%0,4	10	75	7,5	6
Diyabet	HIDER	5	5	-	%74,20	%74,00	%0,2	9	68	7,6	7
Diyabet	HIDER	5	6	-	%74,80	%66,20	%8,6	9	65	7,2	8
Diyabet	HIDER	5	7	-	%75,10	%72,70	%2,4	10	72	7,2	8
Diyabet	HIDER	5	8	-	%75,90	%69,70	%6,2	8	60	7,5	8
Diyabet	HIDER	5	9	-	%77,50	%64,50	%13	12	90	7,5	6
Diyabet	LDWPSO	1	0	80.072	%77,57	%67,53	%10	4	8	2	55,9
Diyabet	LDWPSO	1	1	100.070	%78,15	%72,73	%5,4	6	13	2,2	58,4
Diyabet	LDWPSO	1	2	80.054	%79,74	%74,03	%5,7	4	6	1,5	55,9
Diyabet	LDWPSO	1	3	120.127	%80,17	%70,13	%10	7	18	2,6	64,1
Diyabet	LDWPSO	1	4	100.122	%77,86	%67,53	%10,3	5	11	2,2	60,8
Diyabet	LDWPSO	1	5	100.079	%78,00	%68,83	%9,2	6	10	1,7	69,8
Diyabet	LDWPSO	1	6	100.060	%77,86	%71,43	%6,4	6	11	1,8	62,9
Diyabet	LDWPSO	1	7	100.085	%76,70	%71,43	%5,3	6	11	1,8	63,4
Diyabet	LDWPSO	1	8	100.112	%77,17	%72,37	%4,8	6	12	2	68,9
Diyabet	LDWPSO	1	9	100.074	%78,03	%77,63	%0,4	6	11	1,8	65,4
Diyabet	LDWPSO	2	0	80.085	%79,16	%55,84	%23,3	4	7	1,8	65,9
Diyabet	LDWPSO	2	1	80.092	%77,28	%63,64	%13,6	5	10	2	66,1
Diyabet	LDWPSO	2	2	100.096	%78,44	%72,73	%5,7	6	11	1,8	76,6
Diyabet	LDWPSO	2	3	80.074	%77,71	%57,14	%20,6	5	8	1,6	64,8
Diyabet	LDWPSO	2	4	100.092	%77,71	%68,83	%8,9	6	12	2	77,2
Diyabet	LDWPSO	2	5	100.110	%78,29	%70,13	%8,2	6	12	2	70,8
Diyabet	LDWPSO	2	6	100.117	%76,99	%66,23	%10,8	6	11	1,8	77,8
Diyabet	LDWPSO	2	7	100.127	%78,15	%72,73	%5,4	6	16	2,7	73
Diyabet	LDWPSO	2	8	80.087	%77,75	%73,68	%4,1	4	5	1,3	61
Diyabet	LDWPSO	2	9	80.103	%78,76	%71,05	%7,7	4	7	1,8	60
Diyabet	LDWPSO	3	0	80.096	%78,73	%61,04	%17,7	5	12	2,4	58,7
Diyabet	LDWPSO	3	1	100.174	%78,87	%66,23	%12,6	6	17	2,8	86,5
Diyabet	LDWPSO	3	2	80.101	%77,71	%75,32	%2,4	5	12	2,4	61,2
Diyabet	LDWPSO	3	3	100.126	%78,29	%67,53	%10,8	5	13	2,6	67,8
Diyabet	LDWPSO	3	4	100.130	%78,29	%74,03	%4,3	6	14	2,3	70,9
Diyabet	LDWPSO	3	5	80.057	%80,03	%71,43	%8,6	5	11	2,2	64
Diyabet	LDWPSO	3	6	120.189	%79,31	%75,32	%4	7	20	2,9	71,7
Diyabet	LDWPSO	3	7	100.097	%78,00	%71,43	%6,6	5	9	1,8	77,1
Diyabet	LDWPSO	3	8	80.092	%77,89	%69,74	%8,2	5	13	2,6	64,2
Diyabet	LDWPSO	3	9	80.115	%75,87	%65,79	%10,1	4	11	2,8	61,2
Diyabet	LDWPSO	4	0	100.088	%79,88	%68,83	%11,1	6	11	1,8	70,1
Diyabet	LDWPSO	4	1	100.109	%79,45	%71,43	%8	6	13	2,2	68,2
Diyabet	LDWPSO	4	2	100.082	%79,02	%75,32	%3,7	6	13	2,2	71,9
Diyabet	LDWPSO	4	3	120.107	%76,85	%72,73	%4,1	7	14	2	77,6
Diyabet	LDWPSO	4	4	100.153	%79,59	%63,64	%16	6	16	2,7	64,2
Diyabet	LDWPSO	4	5	80.090	%77,28	%72,73	%4,6	5	11	2,2	72,7
Diyabet	LDWPSO	4	6	100.099	%79,31	%72,73	%6,6	6	14	2,3	66,2
Diyabet	LDWPSO	4	7	100.105	%79,02	%62,34	%16,7	6	14	2,3	79
Diyabet	LDWPSO	4	8	100.096	%78,18	%76,32	%1,9	6	12	2	65,5
Diyabet	LDWPSO	4	9	100.154	%79,77	%61,84	%17,9	6	18	3	71,3
Diyabet	LDWPSO	5	0	100.172	%80,03	%64,94	%15,1	6	18	3	58
Diyabet	LDWPSO	5	1	100.123	%79,59	%68,83	%10,8	6	16	2,7	58
Diyabet	LDWPSO	5	2	100.078	%77,71	%64,94	%12,8	5	10	2	61,9
Diyabet	LDWPSO	5	3	100.116	%78,87	%72,73	%6,1	6	15	2,5	57,6
Diyabet	LDWPSO	5	4	100.059	%78,44	%74,03	%4,4	6	11	1,8	55,8
Diyabet	LDWPSO	5	5	100.117	%79,45	%72,73	%6,7	6	14	2,3	66,7
Diyabet	LDWPSO	5	6	100.117	%78,29	%68,83	%9,5	6	13	2,2	59,3
Diyabet	LDWPSO	5	7	100.070	%78,44	%64,94	%13,5	6	13	2,2	62,3
Diyabet	LDWPSO	5	8	100.085	%76,59	%80,26	-3,7%	6	11	1,8	64
Diyabet	LDWPSO	5	9	80.113	%80,06	%67,11	%13	5	13	2,6	55,6
Diyabet	PGIRLA	1	0	-	%79,74	%81,82	-2,1%	20	66	3,3	3
Diyabet	PGIRLA	1	1	-	%78,73	%79,22	-0,5%	20	67	3,4	2
Diyabet	PGIRLA	1	2	-	%77,13	%71,43	%5,7	20	63	3,2	3
Diyabet	PGIRLA	1	3	-	%77,86	%75,32	%2,5	20	61	3,1	2
Diyabet	PGIRLA	1	4	-	%79,02	%79,22	-0,2%	20	65	3,3	3
Diyabet	PGIRLA	1	5	-	%78,44	%75,32	%3,1	20	59	3	2
Diyabet	PGIRLA	1	6	-	%79,31	%66,23	%13,1	20	66	3,3	3
Diyabet	PGIRLA	1	7	-	%79,45	%72,73	%6,7	20	63	3,2	2
Diyabet	PGIRLA	1	8	-	%76,59	%73,68	%2,9	20	61	3,1	3
Diyabet	PGIRLA	1	9	-	%78,47	%69,74	%8,7	20	66	3,3	2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Diyabet	PGIRLA	2	0	-	%78,73	%72,73	%6	20	58	2,9	3
Diyabet	PGIRLA	2	1	-	%77,13	%71,43	%5,7	20	55	2,8	2
Diyabet	PGIRLA	2	2	-	%78,58	%75,32	%3,3	20	60	3	3
Diyabet	PGIRLA	2	3	-	%78,15	%74,03	%4,1	20	70	3,5	2
Diyabet	PGIRLA	2	4	-	%78,00	%76,62	%1,4	20	63	3,2	3
Diyabet	PGIRLA	2	5	-	%78,15	%72,73	%5,4	20	59	3	2
Diyabet	PGIRLA	2	6	-	%77,13	%64,94	%12,2	20	75	3,8	3
Diyabet	PGIRLA	2	7	-	%76,70	%77,92	-1,2%	20	69	3,5	2
Diyabet	PGIRLA	2	8	-	%76,88	%67,11	%9,8	20	59	3	3
Diyabet	PGIRLA	2	9	-	%78,47	%76,32	%2,2	20	62	3,1	2
Diyabet	PGIRLA	3	0	-	%78,58	%71,43	%7,2	20	56	2,8	3
Diyabet	PGIRLA	3	1	-	%78,44	%72,73	%5,7	20	57	2,9	2
Diyabet	PGIRLA	3	2	-	%78,15	%71,43	%6,7	20	67	3,4	3
Diyabet	PGIRLA	3	3	-	%76,27	%76,62	-0,4%	20	66	3,3	2
Diyabet	PGIRLA	3	4	-	%78,44	%77,92	%0,5	20	65	3,3	3
Diyabet	PGIRLA	3	5	-	%77,71	%72,73	%5	20	60	3	2
Diyabet	PGIRLA	3	6	-	%78,58	%68,83	%9,8	20	67	3,4	3
Diyabet	PGIRLA	3	7	-	%77,28	%77,92	-0,6%	20	71	3,6	2
Diyabet	PGIRLA	3	8	-	%77,75	%69,74	%8	20	58	2,9	3
Diyabet	PGIRLA	3	9	-	%77,89	%73,68	%4,2	20	70	3,5	2
Diyabet	PGIRLA	4	0	-	%77,28	%70,13	%7,1	20	66	3,3	3
Diyabet	PGIRLA	4	1	-	%77,28	%72,73	%4,6	20	58	2,9	2
Diyabet	PGIRLA	4	2	-	%76,85	%70,13	%6,7	20	64	3,2	3
Diyabet	PGIRLA	4	3	-	%77,13	%79,22	-2,1%	20	56	2,8	2
Diyabet	PGIRLA	4	4	-	%77,13	%77,92	-0,8%	20	61	3,1	3
Diyabet	PGIRLA	4	5	-	%78,00	%70,13	%7,9	20	68	3,4	2
Diyabet	PGIRLA	4	6	-	%78,15	%64,94	%13,2	20	58	2,9	3
Diyabet	PGIRLA	4	7	-	%78,00	%76,62	%1,4	20	63	3,2	2
Diyabet	PGIRLA	4	8	-	%77,89	%72,37	%5,5	20	54	2,7	3
Diyabet	PGIRLA	4	9	-	%76,73	%68,42	%8,3	20	66	3,3	2
Diyabet	PGIRLA	5	0	-	%77,42	%66,23	%11,2	20	61	3,1	3
Diyabet	PGIRLA	5	1	-	%78,73	%71,43	%7,3	20	58	2,9	2
Diyabet	PGIRLA	5	2	-	%78,58	%74,03	%4,6	20	60	3	3
Diyabet	PGIRLA	5	3	-	%77,86	%72,73	%5,1	20	62	3,1	2
Diyabet	PGIRLA	5	4	-	%78,44	%79,22	-0,8%	20	67	3,4	3
Diyabet	PGIRLA	5	5	-	%78,44	%77,92	%0,5	20	64	3,2	2
Diyabet	PGIRLA	5	6	-	%79,02	%66,23	%12,8	20	70	3,5	3
Diyabet	PGIRLA	5	7	-	%79,31	%74,03	%5,3	20	70	3,5	2
Diyabet	PGIRLA	5	8	-	%78,18	%71,05	%7,1	20	53	2,7	3
Diyabet	PGIRLA	5	9	-	%79,19	%75,00	%4,2	20	73	3,7	2
Diyabet	SIA	1	0	-	%100	%68,83	%31,2	568	4174	7,3	53
Diyabet	SIA	1	1	-	%100	%70,13	%29,9	586	4541	7,7	56
Diyabet	SIA	1	2	-	%100	%66,23	%33,8	627	4512	7,2	56
Diyabet	SIA	1	3	-	%100	%70,13	%29,9	585	4303	7,4	51
Diyabet	SIA	1	4	-	%100	%74,03	%26	574	3836	6,7	54
Diyabet	SIA	1	5	-	%100	%70,13	%29,9	591	4321	7,3	52
Diyabet	SIA	1	6	-	%100	%68,83	%31,2	605	4565	7,5	54
Diyabet	SIA	1	7	-	%100	%72,73	%27,3	593	4334	7,3	52
Diyabet	SIA	1	8	-	%100	%68,42	%31,6	598	4416	7,4	55
Diyabet	SIA	1	9	-	%100	%68,42	%31,6	615	4282	7	55
Diyabet	SIA	2	0	-	%100	%68,83	%31,2	616	4639	7,5	56
Diyabet	SIA	2	1	-	%100	%67,53	%32,5	621	4591	7,4	58
Diyabet	SIA	2	2	-	%100	%68,83	%31,2	624	4700	7,5	62
Diyabet	SIA	2	3	-	%100	%70,13	%29,9	587	4625	7,9	51
Diyabet	SIA	2	4	-	%100	%79,22	%20,8	608	4764	7,8	55
Diyabet	SIA	2	5	-	%100	%68,83	%31,2	608	4305	7,1	60
Diyabet	SIA	2	6	-	%100	%67,53	%32,5	604	4328	7,2	54
Diyabet	SIA	2	7	-	%100	%68,83	%31,2	602	4420	7,3	53
Diyabet	SIA	2	8	-	%100	%72,37	%27,6	592	4434	7,5	52
Diyabet	SIA	2	9	-	%100	%78,95	%21,1	589	4408	7,5	52
Diyabet	SIA	3	0	-	%100	%66,23	%33,8	610	4195	6,9	51
Diyabet	SIA	3	1	-	%100	%74,03	%26	591	4478	7,6	54
Diyabet	SIA	3	2	-	%100	%64,94	%35,1	635	4471	7	55
Diyabet	SIA	3	3	-	%100	%76,62	%23,4	602	4405	7,3	51
Diyabet	SIA	3	4	-	%100	%76,62	%23,4	612	4785	7,8	57
Diyabet	SIA	3	5	-	%100	%72,73	%27,3	581	4316	7,4	55

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Diyabet	SIA	3	6	-	%100	%67,53	%32,5	612	4471	7,3	53
Diyabet	SIA	3	7	-	%100	%76,62	%23,4	609	4279	7	54
Diyabet	SIA	3	8	-	%100	%76,32	%23,7	607	4356	7,2	52
Diyabet	SIA	3	9	-	%100	%71,05	%28,9	634	4328	6,8	57
Diyabet	SIA	4	0	-	%100	%62,34	%37,7	583	4476	7,7	52
Diyabet	SIA	4	1	-	%100	%74,03	%26	596	4457	7,5	54
Diyabet	SIA	4	2	-	%100	%63,64	%36,4	625	4553	7,3	53
Diyabet	SIA	4	3	-	%100	%77,92	%22,1	606	4182	6,9	55
Diyabet	SIA	4	4	-	%100	%83,12	%16,9	597	4119	6,9	51
Diyabet	SIA	4	5	-	%100	%74,03	%26	595	4343	7,3	59
Diyabet	SIA	4	6	-	%100	%72,73	%27,3	569	4446	7,8	49
Diyabet	SIA	4	7	-	%100	%72,73	%27,3	583	4499	7,7	50
Diyabet	SIA	4	8	-	%100	%68,42	%31,6	586	4298	7,3	52
Diyabet	SIA	4	9	-	%100	%69,74	%30,3	576	4317	7,5	49
Diyabet	SIA	5	0	-	%100	%68,83	%31,2	522	4410	8,4	46
Diyabet	SIA	5	1	-	%100	%72,73	%27,3	582	4365	7,5	51
Diyabet	SIA	5	2	-	%100	%64,94	%35,1	648	4482	6,9	56
Diyabet	SIA	5	3	-	%100	%74,03	%26	599	4306	7,2	54
Diyabet	SIA	5	4	-	%100	%80,52	%19,5	647	4494	6,9	51
Diyabet	SIA	5	5	-	%100	%74,03	%26	592	4507	7,6	49
Diyabet	SIA	5	6	-	%100	%70,13	%29,9	560	4343	7,8	44
Diyabet	SIA	5	7	-	%100	%70,13	%29,9	589	4704	8	47
Diyabet	SIA	5	8	-	%100	%73,68	%26,3	608	4239	7	47
Diyabet	SIA	5	9	-	%100	%72,37	%27,6	610	4517	7,4	49
E.Coli Gen Dizisi	ABCMiner	1	0	141.279	%84,21	%90,91	-6,7%	8	7	0,9	1.013,2
E.Coli Gen Dizisi	ABCMiner	1	1	121.098	%82,11	%63,64	%18,5	6	5	0,8	865,3
E.Coli Gen Dizisi	ABCMiner	1	2	121.092	%80,00	%72,73	%7,3	7	6	0,9	872,6
E.Coli Gen Dizisi	ABCMiner	1	3	141.301	%75,79	%72,73	%3,1	8	7	0,9	882,2
E.Coli Gen Dizisi	ABCMiner	1	4	121.103	%84,21	%81,82	%2,4	7	6	0,9	791,2
E.Coli Gen Dizisi	ABCMiner	1	5	161.489	%76,84	%63,64	%13,2	9	8	0,9	949,1
E.Coli Gen Dizisi	ABCMiner	1	6	141.309	%73,96	%70,00	%4	7	6	0,9	966,9
E.Coli Gen Dizisi	ABCMiner	1	7	121.104	%88,54	%60,00	%28,5	7	6	0,9	757,4
E.Coli Gen Dizisi	ABCMiner	1	8	141.278	%87,50	%50,00	%37,5	8	7	0,9	986,7
E.Coli Gen Dizisi	ABCMiner	1	9	141.279	%81,25	%90,00	-8,8%	8	8	1	973,7
E.Coli Gen Dizisi	ABCMiner	2	0	121.110	%86,32	%63,64	%22,7	7	6	0,9	893
E.Coli Gen Dizisi	ABCMiner	2	1	141.291	%75,79	%72,73	%3,1	7	6	0,9	1.061,8
E.Coli Gen Dizisi	ABCMiner	2	2	141.316	%75,79	%63,64	%12,2	8	7	0,9	991,1
E.Coli Gen Dizisi	ABCMiner	2	3	141.293	%83,16	%81,82	%1,3	8	7	0,9	996,8
E.Coli Gen Dizisi	ABCMiner	2	4	161.476	%80,00	%90,91	-10,9%	9	8	0,9	1.158,4
E.Coli Gen Dizisi	ABCMiner	2	5	141.317	%83,16	%81,82	%1,3	8	7	0,9	933,5
E.Coli Gen Dizisi	ABCMiner	2	6	121.108	%85,42	%60,00	%25,4	7	6	0,9	797
E.Coli Gen Dizisi	ABCMiner	2	7	141.304	%83,33	%70,00	%13,3	8	7	0,9	822,9
E.Coli Gen Dizisi	ABCMiner	2	8	161.493	%80,21	%40,00	%40,2	9	8	0,9	1.019,3
E.Coli Gen Dizisi	ABCMiner	2	9	141.289	%79,17	%50,00	%29,2	8	7	0,9	965,9
E.Coli Gen Dizisi	ABCMiner	3	0	161.477	%82,11	%81,82	%0,3	8	7	0,9	1.029
E.Coli Gen Dizisi	ABCMiner	3	1	121.118	%88,42	%63,64	%24,8	7	6	0,9	796,5
E.Coli Gen Dizisi	ABCMiner	3	2	141.291	%82,11	%81,82	%0,3	8	8	1	904,8
E.Coli Gen Dizisi	ABCMiner	3	3	161.465	%78,95	%54,55	%24,4	9	8	0,9	1.047,4
E.Coli Gen Dizisi	ABCMiner	3	4	141.313	%75,79	%54,55	%21,2	8	7	0,9	895,2
E.Coli Gen Dizisi	ABCMiner	3	5	121.108	%85,26	%81,82	%3,4	7	6	0,9	814,2
E.Coli Gen Dizisi	ABCMiner	3	6	141.277	%76,04	%70,00	%6	7	6	0,9	936,6
E.Coli Gen Dizisi	ABCMiner	3	7	141.294	%78,13	%70,00	%8,1	8	7	0,9	1.014,5
E.Coli Gen Dizisi	ABCMiner	3	8	141.303	%80,21	%90,00	-9,8%	8	7	0,9	879,8
E.Coli Gen Dizisi	ABCMiner	3	9	141.298	%78,13	%80,00	-1,9%	8	7	0,9	1.008,7
E.Coli Gen Dizisi	ABCMiner	4	0	141.279	%75,79	%72,73	%3,1	8	7	0,9	935,6
E.Coli Gen Dizisi	ABCMiner	4	1	161.462	%75,79	%81,82	-6,0%	9	8	0,9	1.023
E.Coli Gen Dizisi	ABCMiner	4	2	121.113	%88,42	%90,91	-2,5%	6	5	0,8	829,8
E.Coli Gen Dizisi	ABCMiner	4	3	161.495	%73,68	%81,82	-8,1%	9	9	1	961,6
E.Coli Gen Dizisi	ABCMiner	4	4	141.297	%82,11	%90,91	-8,8%	8	7	0,9	746
E.Coli Gen Dizisi	ABCMiner	4	5	141.293	%78,95	%36,36	%42,6	8	7	0,9	897
E.Coli Gen Dizisi	ABCMiner	4	6	141.292	%83,33	%70,00	%13,3	8	7	0,9	800,1
E.Coli Gen Dizisi	ABCMiner	4	7	141.298	%83,33	%80,00	%3,3	8	7	0,9	846,8
E.Coli Gen Dizisi	ABCMiner	4	8	121.119	%83,33	%80,00	%3,3	6	5	0,8	729,1
E.Coli Gen Dizisi	ABCMiner	4	9	161.501	%80,21	%50,00	%30,2	9	8	0,9	928
E.Coli Gen Dizisi	ABCMiner	5	0	121.115	%86,32	%72,73	%13,6	5	4	0,8	798,3
E.Coli Gen Dizisi	ABCMiner	5	1	121.090	%83,16	%54,55	%28,6	7	6	0,9	906,6

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
E.Coli Gen Dizisi	ABCMiner	5	2	121.096	%83,16	%45,45	%37,7	7	6	0,9	748,1
E.Coli Gen Dizisi	ABCMiner	5	3	121.099	%81,05	%90,91	-9,9%	7	6	0,9	792,9
E.Coli Gen Dizisi	ABCMiner	5	4	121.104	%83,16	%81,82	%1,3	7	6	0,9	688,7
E.Coli Gen Dizisi	ABCMiner	5	5	141.311	%87,37	%63,64	%23,7	8	8	1	730,8
E.Coli Gen Dizisi	ABCMiner	5	6	121.114	%82,29	%30,00	%52,3	7	6	0,9	747,1
E.Coli Gen Dizisi	ABCMiner	5	7	121.101	%84,38	%70,00	%14,4	7	6	0,9	695,9
E.Coli Gen Dizisi	ABCMiner	5	8	121.117	%87,50	%50,00	%37,5	7	6	0,9	685,2
E.Coli Gen Dizisi	ABCMiner	5	9	121.123	%80,21	%70,00	%10,2	7	6	0,9	742
E.Coli Gen Dizisi	C4.5	-	1	-	%95,79	%72,73	%23,1	12	18	1,5	0,3
E.Coli Gen Dizisi	C4.5	-	2	-	%95,79	%81,82	%14	8	12	1,5	0,3
E.Coli Gen Dizisi	C4.5	-	3	-	%94,74	%72,73	%22	8	12	1,5	0,3
E.Coli Gen Dizisi	C4.5	-	4	-	%95,79	%100	-4,2%	11	17	1,5	0,3
E.Coli Gen Dizisi	C4.5	-	5	-	%88,42	%81,82	%6,6	11	19	1,7	0,3
E.Coli Gen Dizisi	C4.5	-	6	-	%88,42	%63,64	%24,8	8	10	1,3	0,3
E.Coli Gen Dizisi	C4.5	-	7	-	%92,71	%90,00	%2,7	10	18	1,8	0,3
E.Coli Gen Dizisi	C4.5	-	8	-	%92,71	%60,00	%32,7	7	10	1,4	0,3
E.Coli Gen Dizisi	C4.5	-	9	-	%95,83	%70,00	%25,8	8	11	1,4	0,3
E.Coli Gen Dizisi	C4.5	-	10	-	%91,67	%80,00	%11,7	10	14	1,4	0,3
E.Coli Gen Dizisi	CoABCMiner	1	0	110.414	%97,89	%90,91	%7	8	35	4,4	1,5
E.Coli Gen Dizisi	CoABCMiner	1	1	110.419	%94,74	%100	-5,3%	9	39	4,3	1,6
E.Coli Gen Dizisi	CoABCMiner	1	2	110.412	%96,84	%100	-3,2%	6	23	3,8	1,7
E.Coli Gen Dizisi	CoABCMiner	1	3	110.424	%96,84	%81,82	%15	8	30	3,8	1,6
E.Coli Gen Dizisi	CoABCMiner	1	4	110.402	%97,89	%81,82	%16,1	8	33	4,1	1,6
E.Coli Gen Dizisi	CoABCMiner	1	5	110.396	%97,89	%72,73	%25,2	6	20	3,3	1,7
E.Coli Gen Dizisi	CoABCMiner	1	6	110.418	%96,88	%90,00	%6,9	10	42	4,2	1,7
E.Coli Gen Dizisi	CoABCMiner	1	7	110.417	%95,83	%80,00	%15,8	8	31	3,9	1,7
E.Coli Gen Dizisi	CoABCMiner	1	8	110.414	%96,88	%80,00	%16,9	6	23	3,8	1,8
E.Coli Gen Dizisi	CoABCMiner	1	9	110.417	%94,79	%70,00	%24,8	9	32	3,6	1,8
E.Coli Gen Dizisi	CoABCMiner	2	0	110.415	%98,95	%90,91	%8	7	25	3,6	1,3
E.Coli Gen Dizisi	CoABCMiner	2	1	110.415	%95,79	%90,91	%4,9	9	32	3,6	1,3
E.Coli Gen Dizisi	CoABCMiner	2	2	110.422	%95,79	%100	-4,2%	7	22	3,1	1,3
E.Coli Gen Dizisi	CoABCMiner	2	3	110.418	%97,89	%100	-2,1%	8	34	4,3	1,3
E.Coli Gen Dizisi	CoABCMiner	2	4	110.412	%96,84	%81,82	%15	7	32	4,6	1,5
E.Coli Gen Dizisi	CoABCMiner	2	5	110.406	%98,95	%81,82	%17,1	7	23	3,3	1,4
E.Coli Gen Dizisi	CoABCMiner	2	6	110.408	%97,92	%90,00	%7,9	9	32	3,6	1,4
E.Coli Gen Dizisi	CoABCMiner	2	7	110.406	%96,88	%70,00	%26,9	9	39	4,3	1,4
E.Coli Gen Dizisi	CoABCMiner	2	8	110.415	%97,92	%60,00	%37,9	7	22	3,1	1,4
E.Coli Gen Dizisi	CoABCMiner	2	9	110.405	%96,88	%100	-3,1%	7	27	3,9	1,4
E.Coli Gen Dizisi	CoABCMiner	3	0	110.409	%96,84	%100	-3,2%	9	36	4	1,5
E.Coli Gen Dizisi	CoABCMiner	3	1	110.418	%94,74	%81,82	%12,9	8	33	4,1	1,5
E.Coli Gen Dizisi	CoABCMiner	3	2	110.396	%95,79	%72,73	%23,1	9	30	3,3	1,5
E.Coli Gen Dizisi	CoABCMiner	3	3	110.405	%94,74	%81,82	%12,9	6	23	3,8	1,5
E.Coli Gen Dizisi	CoABCMiner	3	4	110.409	%97,89	%81,82	%16,1	9	36	4	1,4
E.Coli Gen Dizisi	CoABCMiner	3	5	110.413	%96,84	%81,82	%15	10	42	4,2	1,5
E.Coli Gen Dizisi	CoABCMiner	3	6	110.436	%95,83	%70,00	%25,8	8	33	4,1	1,5
E.Coli Gen Dizisi	CoABCMiner	3	7	110.414	%95,83	%60,00	%35,8	7	23	3,3	1,5
E.Coli Gen Dizisi	CoABCMiner	3	8	110.423	%96,88	%100	-3,1%	5	16	3,2	1,4
E.Coli Gen Dizisi	CoABCMiner	3	9	110.414	%95,83	%80,00	%15,8	9	41	4,6	1,6
E.Coli Gen Dizisi	CoABCMiner	4	0	110.412	%95,79	%72,73	%23,1	8	32	4	1,6
E.Coli Gen Dizisi	CoABCMiner	4	1	110.420	%95,79	%100	-4,2%	6	22	3,7	1,5
E.Coli Gen Dizisi	CoABCMiner	4	2	110.388	%96,84	%81,82	%15	6	24	4	1,6
E.Coli Gen Dizisi	CoABCMiner	4	3	110.426	%93,68	%90,91	%2,8	5	18	3,6	1,6
E.Coli Gen Dizisi	CoABCMiner	4	4	110.409	%96,84	%72,73	%24,1	10	44	4,4	1,6
E.Coli Gen Dizisi	CoABCMiner	4	5	110.422	%96,84	%81,82	%15	7	22	3,1	1,4
E.Coli Gen Dizisi	CoABCMiner	4	6	110.409	%95,83	%80,00	%15,8	8	31	3,9	1,5
E.Coli Gen Dizisi	CoABCMiner	4	7	110.413	%96,88	%90,00	%6,9	8	29	3,6	1,6
E.Coli Gen Dizisi	CoABCMiner	4	8	110.409	%96,88	%80,00	%16,9	9	38	4,2	1,5
E.Coli Gen Dizisi	CoABCMiner	4	9	110.414	%97,92	%80,00	%17,9	7	31	4,4	1,5
E.Coli Gen Dizisi	CoABCMiner	5	0	110.420	%96,84	%90,91	%5,9	7	24	3,4	1,6
E.Coli Gen Dizisi	CoABCMiner	5	1	110.414	%97,89	%100	-2,1%	8	28	3,5	1,6
E.Coli Gen Dizisi	CoABCMiner	5	2	110.400	%98,95	%81,82	%17,1	8	29	3,6	1,7
E.Coli Gen Dizisi	CoABCMiner	5	3	110.407	%96,84	%81,82	%15	10	38	3,8	1,7
E.Coli Gen Dizisi	CoABCMiner	5	4	110.402	%96,84	%81,82	%15	8	31	3,9	1,7
E.Coli Gen Dizisi	CoABCMiner	5	5	110.396	%96,84	%81,82	%15	6	20	3,3	1,8
E.Coli Gen Dizisi	CoABCMiner	5	6	110.415	%96,88	%80,00	%16,9	9	33	3,7	1,8
E.Coli Gen Dizisi	CoABCMiner	5	7	110.418	%98,96	%90,00	%9	7	20	2,9	1,8

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
E.Coli Gen Dizisi	CoABCMiner	5	8	110.398	%96,88	%70,00	%26,9	7	27	3,9	1,8
E.Coli Gen Dizisi	CoABCMiner	5	9	110.404	%95,83	%90,00	%5,8	9	31	3,4	1,8
E.Coli Gen Dizisi	CORE	1	0	1.966.537	%50,53	%45,45	%5,1	1	15	15	57,5
E.Coli Gen Dizisi	CORE	1	1	1.967.092	%50,53	%45,45	%5,1	1	15	15	58
E.Coli Gen Dizisi	CORE	1	2	1.966.537	%50,53	%45,45	%5,1	1	15	15	57,9
E.Coli Gen Dizisi	CORE	1	3	1.966.537	%51,58	%45,45	%6,1	1	15	15	58,2
E.Coli Gen Dizisi	CORE	1	4	1.967.589	%50,53	%45,45	%5,1	1	17	17	55,1
E.Coli Gen Dizisi	CORE	1	5	1.966.537	%51,58	%45,45	%6,1	1	15	15	57,4
E.Coli Gen Dizisi	CORE	1	6	1.966.537	%51,04	%50,00	%1	1	15	15	57,7
E.Coli Gen Dizisi	CORE	1	7	1.965.938	%52,08	%50,00	%2,1	2	31	15,5	58,6
E.Coli Gen Dizisi	CORE	1	8	1.966.537	%51,04	%50,00	%1	1	15	15	57,7
E.Coli Gen Dizisi	CORE	1	9	1.966.537	%51,04	%50,00	%1	1	15	15	57,9
E.Coli Gen Dizisi	CORE	2	0	-	%51,58	%45,45	%6,1	2	26	13	57,2
E.Coli Gen Dizisi	CORE	2	1	-	%50,53	%45,45	%5,1	1	17	17	56,5
E.Coli Gen Dizisi	CORE	2	2	-	%50,53	%45,45	%5,1	1	17	17	56,5
E.Coli Gen Dizisi	CORE	2	3	-	%50,53	%45,45	%5,1	1	17	17	55,5
E.Coli Gen Dizisi	CORE	2	4	-	%50,53	%45,45	%5,1	1	17	17	55,8
E.Coli Gen Dizisi	CORE	2	5	-	%50,53	%45,45	%5,1	1	17	17	55,9
E.Coli Gen Dizisi	CORE	2	6	-	%50,00	%50,00	%0	1	17	17	56,9
E.Coli Gen Dizisi	CORE	2	7	-	%50,00	%50,00	%0	1	17	17	55,9
E.Coli Gen Dizisi	CORE	2	8	-	%50,00	%50,00	%0	1	17	17	56
E.Coli Gen Dizisi	CORE	2	9	-	%50,00	%50,00	%0	1	17	17	56
E.Coli Gen Dizisi	CORE	3	0	-	%52,63	%45,45	%7,2	3	51	17	57,4
E.Coli Gen Dizisi	CORE	3	1	-	%52,63	%45,45	%7,2	3	51	17	57,8
E.Coli Gen Dizisi	CORE	3	2	-	%51,58	%45,45	%6,1	1	22	22	57,1
E.Coli Gen Dizisi	CORE	3	3	-	%52,63	%45,45	%7,2	3	38	12,7	58,2
E.Coli Gen Dizisi	CORE	3	4	-	%49,47	%36,36	%13,1	3	51	17	58,1
E.Coli Gen Dizisi	CORE	3	5	-	%52,63	%45,45	%7,2	4	69	17,3	60,6
E.Coli Gen Dizisi	CORE	3	6	-	%50,00	%50,00	%0	1	22	22	57,6
E.Coli Gen Dizisi	CORE	3	7	-	%47,92	%50,00	-2,1%	3	51	17	58,7
E.Coli Gen Dizisi	CORE	3	8	-	%50,00	%50,00	%0	1	22	22	57,3
E.Coli Gen Dizisi	CORE	3	9	-	%48,96	%40,00	%9	3	51	17	58,9
E.Coli Gen Dizisi	CORE	4	0	-	%50,53	%45,45	%5,1	1	14	14	55,7
E.Coli Gen Dizisi	CORE	4	1	-	%50,53	%45,45	%5,1	1	14	14	54,3
E.Coli Gen Dizisi	CORE	4	2	-	%50,53	%45,45	%5,1	1	14	14	55,3
E.Coli Gen Dizisi	CORE	4	3	-	%50,53	%45,45	%5,1	1	14	14	55,6
E.Coli Gen Dizisi	CORE	4	4	-	%50,53	%45,45	%5,1	1	14	14	55,6
E.Coli Gen Dizisi	CORE	4	5	-	%51,58	%45,45	%6,1	1	16	16	55,5
E.Coli Gen Dizisi	CORE	4	6	-	%50,00	%50,00	%0	1	14	14	55,6
E.Coli Gen Dizisi	CORE	4	7	-	%50,00	%50,00	%0	1	14	14	56
E.Coli Gen Dizisi	CORE	4	8	-	%50,00	%50,00	%0	1	18	18	55
E.Coli Gen Dizisi	CORE	4	9	-	%50,00	%50,00	%0	1	14	14	54,7
E.Coli Gen Dizisi	CORE	5	0	-	%55,79	%54,55	%1,2	11	191	17,4	59,5
E.Coli Gen Dizisi	CORE	5	1	-	%50,53	%45,45	%5,1	2	28	14	56
E.Coli Gen Dizisi	CORE	5	2	-	%53,68	%45,45	%8,2	3	35	11,7	56,4
E.Coli Gen Dizisi	CORE	5	3	-	%50,53	%45,45	%5,1	1	18	18	55,9
E.Coli Gen Dizisi	CORE	5	4	-	%52,63	%45,45	%7,2	12	166	13,8	63,4
E.Coli Gen Dizisi	CORE	5	5	-	%52,63	%45,45	%7,2	12	161	13,4	62,1
E.Coli Gen Dizisi	CORE	5	6	-	%51,04	%50,00	%1	13	180	13,8	62,3
E.Coli Gen Dizisi	CORE	5	7	-	%51,04	%50,00	%1	2	24	12	57,8
E.Coli Gen Dizisi	CORE	5	8	-	%52,08	%50,00	%2,1	2	29	14,5	55,8
E.Coli Gen Dizisi	CORE	5	9	-	%53,13	%50,00	%3,1	10	125	12,5	61,6
E.Coli Gen Dizisi	HIDER	1	0	-	%94,70	%27,30	%67,4	67	1302	19,4	129
E.Coli Gen Dizisi	HIDER	1	1	-	%95,80	%0,00	%95,8	76	1462	19,2	149
E.Coli Gen Dizisi	HIDER	1	2	-	%95,80	%18,20	%77,6	75	1461	19,5	146
E.Coli Gen Dizisi	HIDER	1	3	-	%95,80	%54,50	%41,3	61	1030	16,9	126
E.Coli Gen Dizisi	HIDER	1	4	-	%95,80	%9,10	%86,7	74	1364	18,4	147
E.Coli Gen Dizisi	HIDER	1	5	-	%94,70	%0,00	%94,7	79	1657	21	161
E.Coli Gen Dizisi	HIDER	1	6	-	%95,80	%10,00	%85,8	72	1441	20	147
E.Coli Gen Dizisi	HIDER	1	7	-	%95,80	%20,00	%75,8	65	1144	17,6	128
E.Coli Gen Dizisi	HIDER	1	8	-	%95,80	%30,00	%65,8	76	1413	18,6	156
E.Coli Gen Dizisi	HIDER	1	9	-	%95,80	%10,00	%85,8	79	1528	19,3	157
E.Coli Gen Dizisi	HIDER	2	0	-	%95,80	%0,00	%95,8	72	1408	19,6	129
E.Coli Gen Dizisi	HIDER	2	1	-	%95,80	%9,10	%86,7	67	1261	18,8	149
E.Coli Gen Dizisi	HIDER	2	2	-	%95,80	%18,20	%77,6	77	1504	19,5	146
E.Coli Gen Dizisi	HIDER	2	3	-	%95,80	%9,10	%86,7	64	1065	16,6	126

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
E.Coli Gen Dizisi	HIDER	2	4	-	%94,70	%9,10	%85,6	72	1348	18,7	147
E.Coli Gen Dizisi	HIDER	2	5	-	%94,70	%9,10	%85,6	76	1585	20,9	161
E.Coli Gen Dizisi	HIDER	2	6	-	%95,80	%10,00	%85,8	75	1518	20,2	147
E.Coli Gen Dizisi	HIDER	2	7	-	%95,80	%0,00	%95,8	68	1201	17,7	128
E.Coli Gen Dizisi	HIDER	2	8	-	%95,80	%0,00	%95,8	75	1366	18,2	156
E.Coli Gen Dizisi	HIDER	2	9	-	%95,80	%20,00	%75,8	76	1499	19,7	157
E.Coli Gen Dizisi	HIDER	3	0	-	%95,80	%0,00	%95,8	68	1322	19,4	129
E.Coli Gen Dizisi	HIDER	3	1	-	%95,80	%36,40	%59,4	71	1363	19,2	149
E.Coli Gen Dizisi	HIDER	3	2	-	%95,80	%9,10	%86,7	74	1425	19,3	146
E.Coli Gen Dizisi	HIDER	3	3	-	%95,80	%36,40	%59,4	63	1047	16,6	126
E.Coli Gen Dizisi	HIDER	3	4	-	%96,80	%36,40	%60,4	74	1400	18,9	147
E.Coli Gen Dizisi	HIDER	3	5	-	%94,70	%0,00	%94,7	73	1499	20,5	161
E.Coli Gen Dizisi	HIDER	3	6	-	%95,80	%0,00	%95,8	73	1484	20,3	147
E.Coli Gen Dizisi	HIDER	3	7	-	%95,80	%20,00	%75,8	63	1105	17,5	128
E.Coli Gen Dizisi	HIDER	3	8	-	%95,80	%30,00	%65,8	69	1233	17,9	156
E.Coli Gen Dizisi	HIDER	3	9	-	%95,80	%20,00	%75,8	73	1486	20,4	157
E.Coli Gen Dizisi	HIDER	4	0	-	%95,80	%9,10	%86,7	77	1467	19,1	129
E.Coli Gen Dizisi	HIDER	4	1	-	%94,70	%36,40	%58,3	76	1388	18,3	149
E.Coli Gen Dizisi	HIDER	4	2	-	%94,70	%18,20	%76,5	70	1383	19,8	146
E.Coli Gen Dizisi	HIDER	4	3	-	%95,80	%18,20	%77,6	60	990	16,5	126
E.Coli Gen Dizisi	HIDER	4	4	-	%95,80	%36,40	%59,4	68	1318	19,4	147
E.Coli Gen Dizisi	HIDER	4	5	-	%95,80	%0,00	%95,8	80	1681	21	161
E.Coli Gen Dizisi	HIDER	4	6	-	%95,80	%20,00	%75,8	73	1468	20,1	147
E.Coli Gen Dizisi	HIDER	4	7	-	%95,80	%0,00	%95,8	73	1283	17,6	128
E.Coli Gen Dizisi	HIDER	4	8	-	%95,80	%30,00	%65,8	71	1296	18,3	156
E.Coli Gen Dizisi	HIDER	4	9	-	%95,80	%0,00	%95,8	70	1388	19,8	157
E.Coli Gen Dizisi	HIDER	5	0	-	%95,80	%9,10	%86,7	69	1314	19	129
E.Coli Gen Dizisi	HIDER	5	1	-	%95,80	%9,10	%86,7	71	1340	18,9	149
E.Coli Gen Dizisi	HIDER	5	2	-	%95,80	%18,20	%77,6	77	1561	20,3	146
E.Coli Gen Dizisi	HIDER	5	3	-	%94,70	%27,30	%67,4	64	1069	16,7	126
E.Coli Gen Dizisi	HIDER	5	4	-	%95,80	%27,30	%68,5	74	1389	18,8	147
E.Coli Gen Dizisi	HIDER	5	5	-	%95,80	%0,00	%95,8	73	1537	21,1	161
E.Coli Gen Dizisi	HIDER	5	6	-	%95,80	%0,00	%95,8	76	1523	20	147
E.Coli Gen Dizisi	HIDER	5	7	-	%95,80	%20,00	%75,8	66	1156	17,5	128
E.Coli Gen Dizisi	HIDER	5	8	-	%95,80	%10,00	%85,8	68	1245	18,3	156
E.Coli Gen Dizisi	HIDER	5	9	-	%95,80	%0,00	%95,8	75	1464	19,5	157
E.Coli Gen Dizisi	LDWPSO	1	0	120.012	%92,63	%90,91	%1,7	7	6	0,9	2.903,8
E.Coli Gen Dizisi	LDWPSO	1	1	120.014	%83,16	%90,91	-7,8%	7	7	1	2.145,4
E.Coli Gen Dizisi	LDWPSO	1	2	120.014	%83,16	%27,27	%55,9	6	5	0,8	4.813,1
E.Coli Gen Dizisi	LDWPSO	1	3	120.014	%85,26	%100	-14,7%	7	6	0,9	4.402,9
E.Coli Gen Dizisi	LDWPSO	1	4	100.010	%86,32	%63,64	%22,7	6	5	0,8	1.306,4
E.Coli Gen Dizisi	LDWPSO	1	5	120.012	%86,32	%72,73	%13,6	7	6	0,9	1.488,1
E.Coli Gen Dizisi	LDWPSO	1	6	120.012	%82,29	%60,00	%22,3	7	6	0,9	1.812,4
E.Coli Gen Dizisi	LDWPSO	1	7	120.012	%86,46	%80,00	%6,5	7	6	0,9	1.450,6
E.Coli Gen Dizisi	LDWPSO	1	8	100.010	%84,38	%70,00	%14,4	6	5	0,8	1.575,4
E.Coli Gen Dizisi	LDWPSO	1	9	100.014	%87,50	%30,00	%57,5	6	5	0,8	1.327,1
E.Coli Gen Dizisi	LDWPSO	2	0	120.012	%87,37	%81,82	%5,6	6	5	0,8	1.979,3
E.Coli Gen Dizisi	LDWPSO	2	1	120.012	%83,16	%45,45	%37,7	6	5	0,8	1.893,6
E.Coli Gen Dizisi	LDWPSO	2	2	100.010	%85,26	%81,82	%3,4	6	5	0,8	1.740,9
E.Coli Gen Dizisi	LDWPSO	2	3	120.014	%77,89	%72,73	%5,2	5	4	0,8	2.322,1
E.Coli Gen Dizisi	LDWPSO	2	4	120.012	%86,32	%72,73	%13,6	6	5	0,8	1.480,8
E.Coli Gen Dizisi	LDWPSO	2	5	120.012	%85,26	%63,64	%21,6	6	5	0,8	1.266,8
E.Coli Gen Dizisi	LDWPSO	2	6	140.016	%82,29	%50,00	%32,3	7	7	1	2.625,4
E.Coli Gen Dizisi	LDWPSO	2	7	120.012	%88,54	%60,00	%28,5	7	6	0,9	2.178,2
E.Coli Gen Dizisi	LDWPSO	2	8	120.012	%88,54	%50,00	%38,5	6	5	0,8	1.320,5
E.Coli Gen Dizisi	LDWPSO	2	9	120.012	%85,42	%30,00	%55,4	6	5	0,8	1.831,2
E.Coli Gen Dizisi	LDWPSO	3	0	120.014	%85,26	%90,91	-5,6%	7	7	1	2.737,3
E.Coli Gen Dizisi	LDWPSO	3	1	120.012	%80,00	%72,73	%7,3	5	4	0,8	3.500,8
E.Coli Gen Dizisi	LDWPSO	3	2	120.012	%86,32	%63,64	%22,7	7	6	0,9	5.225,7
E.Coli Gen Dizisi	LDWPSO	3	3	120.014	%83,16	%72,73	%10,4	7	6	0,9	1.862,7
E.Coli Gen Dizisi	LDWPSO	3	4	120.012	%81,05	%81,82	-0,8%	7	6	0,9	1.391,2
E.Coli Gen Dizisi	LDWPSO	3	5	120.014	%86,32	%63,64	%22,7	6	6	1	1.673,3
E.Coli Gen Dizisi	LDWPSO	3	6	120.012	%77,08	%60,00	%17,1	7	6	0,9	1.673,5
E.Coli Gen Dizisi	LDWPSO	3	7	100.012	%88,54	%60,00	%28,5	6	5	0,8	1.332,1
E.Coli Gen Dizisi	LDWPSO	3	8	120.012	%88,54	%50,00	%38,5	7	6	0,9	1.523,2
E.Coli Gen Dizisi	LDWPSO	3	9	120.012	%87,50	%90,00	-2,5%	6	5	0,8	1.471

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
E.Coli Gen Dizisi	LDWPSO	4	0	120.012	%84,21	%81,82	%2,4	7	6	0,9	2.124,5
E.Coli Gen Dizisi	LDWPSO	4	1	120.016	%78,95	%54,55	%24,4	7	7	1	2.567,9
E.Coli Gen Dizisi	LDWPSO	4	2	120.012	%85,26	%45,45	%39,8	5	4	0,8	2.432,7
E.Coli Gen Dizisi	LDWPSO	4	3	140.018	%80,00	%63,64	%16,4	8	8	1	1.811,7
E.Coli Gen Dizisi	LDWPSO	4	4	120.012	%84,21	%81,82	%2,4	7	6	0,9	1.899
E.Coli Gen Dizisi	LDWPSO	4	5	120.012	%86,32	%54,55	%31,8	7	6	0,9	1.424,3
E.Coli Gen Dizisi	LDWPSO	4	6	120.012	%85,42	%60,00	%25,4	7	6	0,9	2.245,9
E.Coli Gen Dizisi	LDWPSO	4	7	120.014	%85,42	%80,00	%5,4	6	6	1	2.756,1
E.Coli Gen Dizisi	LDWPSO	4	8	120.012	%85,42	%80,00	%5,4	6	5	0,8	1.624,7
E.Coli Gen Dizisi	LDWPSO	4	9	120.012	%73,96	%90,00	-16,0%	5	4	0,8	2.174,7
E.Coli Gen Dizisi	LDWPSO	5	0	120.014	%90,53	%90,91	-0,4%	6	6	1	1.413,8
E.Coli Gen Dizisi	LDWPSO	5	1	120.014	%80,00	%27,27	%52,7	6	6	1	1.719
E.Coli Gen Dizisi	LDWPSO	5	2	140.016	%85,26	%72,73	%12,5	8	8	1	2.212
E.Coli Gen Dizisi	LDWPSO	5	3	120.012	%84,21	%90,91	-6,7%	6	5	0,8	1.635
E.Coli Gen Dizisi	LDWPSO	5	4	140.014	%81,05	%72,73	%8,3	8	7	0,9	1.702,6
E.Coli Gen Dizisi	LDWPSO	5	5	100.010	%87,37	%72,73	%14,6	6	5	0,8	1.299,4
E.Coli Gen Dizisi	LDWPSO	5	6	120.014	%76,04	%40,00	%36	7	6	0,9	1.731,5
E.Coli Gen Dizisi	LDWPSO	5	7	120.012	%83,33	%70,00	%13,3	6	5	0,8	1.470,4
E.Coli Gen Dizisi	LDWPSO	5	8	120.014	%77,08	%40,00	%37,1	7	6	0,9	1.270,7
E.Coli Gen Dizisi	LDWPSO	5	9	120.016	%85,42	%90,00	-4,6%	6	6	1	1.218,6
E.Coli Gen Dizisi	PGIRLA	1	0	-	%58,95	%54,55	%4,4	20	621	31,1	2
E.Coli Gen Dizisi	PGIRLA	1	1	-	%54,74	%54,55	%0,2	20	629	31,5	1
E.Coli Gen Dizisi	PGIRLA	1	2	-	%55,79	%54,55	%1,2	20	618	30,9	2
E.Coli Gen Dizisi	PGIRLA	1	3	-	%60,00	%63,64	-3,6%	20	638	31,9	1
E.Coli Gen Dizisi	PGIRLA	1	4	-	%54,74	%45,45	%9,3	20	607	30,4	2
E.Coli Gen Dizisi	PGIRLA	1	5	-	%63,16	%45,45	%17,7	20	645	32,3	1
E.Coli Gen Dizisi	PGIRLA	1	6	-	%54,17	%50,00	%4,2	20	637	31,9	1
E.Coli Gen Dizisi	PGIRLA	1	7	-	%56,25	%50,00	%6,3	20	617	30,9	2
E.Coli Gen Dizisi	PGIRLA	1	8	-	%60,42	%50,00	%10,4	20	637	31,9	1
E.Coli Gen Dizisi	PGIRLA	1	9	-	%56,25	%50,00	%6,3	20	609	30,5	2
E.Coli Gen Dizisi	PGIRLA	2	0	-	%62,11	%45,45	%16,7	20	630	31,5	2
E.Coli Gen Dizisi	PGIRLA	2	1	-	%61,05	%45,45	%15,6	20	616	30,8	1
E.Coli Gen Dizisi	PGIRLA	2	2	-	%58,95	%54,55	%4,4	20	600	30	2
E.Coli Gen Dizisi	PGIRLA	2	3	-	%56,84	%45,45	%11,4	20	603	30,2	1
E.Coli Gen Dizisi	PGIRLA	2	4	-	%60,00	%45,45	%14,5	20	627	31,4	2
E.Coli Gen Dizisi	PGIRLA	2	5	-	%57,89	%45,45	%12,4	20	638	31,9	1
E.Coli Gen Dizisi	PGIRLA	2	6	-	%68,75	%40,00	%28,8	20	599	30	1
E.Coli Gen Dizisi	PGIRLA	2	7	-	%64,58	%60,00	%4,6	20	622	31,1	2
E.Coli Gen Dizisi	PGIRLA	2	8	-	%63,54	%70,00	-6,5%	20	626	31,3	1
E.Coli Gen Dizisi	PGIRLA	2	9	-	%62,50	%50,00	%12,5	20	624	31,2	2
E.Coli Gen Dizisi	PGIRLA	3	0	-	%67,37	%36,36	%31	20	600	30	2
E.Coli Gen Dizisi	PGIRLA	3	1	-	%53,68	%54,55	-0,9%	20	629	31,5	1
E.Coli Gen Dizisi	PGIRLA	3	2	-	%46,32	%45,45	%0,9	20	592	29,6	2
E.Coli Gen Dizisi	PGIRLA	3	3	-	%53,68	%45,45	%8,2	20	657	32,9	1
E.Coli Gen Dizisi	PGIRLA	3	4	-	%51,58	%54,55	-3,0%	20	625	31,3	2
E.Coli Gen Dizisi	PGIRLA	3	5	-	%62,11	%36,36	%25,7	20	612	30,6	1
E.Coli Gen Dizisi	PGIRLA	3	6	-	%67,71	%20,00	%47,7	20	626	31,3	1
E.Coli Gen Dizisi	PGIRLA	3	7	-	%44,79	%40,00	%4,8	20	629	31,5	2
E.Coli Gen Dizisi	PGIRLA	3	8	-	%56,25	%40,00	%16,3	20	614	30,7	1
E.Coli Gen Dizisi	PGIRLA	3	9	-	%58,33	%40,00	%18,3	20	579	29	2
E.Coli Gen Dizisi	PGIRLA	4	0	-	%22,11	%27,27	-5,2%	20	643	32,2	2
E.Coli Gen Dizisi	PGIRLA	4	1	-	%9,47	%0,00	%9,5	20	655	32,8	1
E.Coli Gen Dizisi	PGIRLA	4	2	-	%42,11	%45,45	-3,3%	20	593	29,7	2
E.Coli Gen Dizisi	PGIRLA	4	3	-	%42,11	%36,36	%5,7	20	628	31,4	1
E.Coli Gen Dizisi	PGIRLA	4	4	-	%54,74	%54,55	%0,2	20	621	31,1	2
E.Coli Gen Dizisi	PGIRLA	4	5	-	%24,21	%18,18	%6	20	613	30,7	1
E.Coli Gen Dizisi	PGIRLA	4	6	-	%25,00	%0,00	%25	20	624	31,2	1
E.Coli Gen Dizisi	PGIRLA	4	7	-	%47,92	%40,00	%7,9	20	635	31,8	2
E.Coli Gen Dizisi	PGIRLA	4	8	-	%38,54	%20,00	%18,5	20	593	29,7	1
E.Coli Gen Dizisi	PGIRLA	4	9	-	%55,21	%50,00	%5,2	20	619	31	2
E.Coli Gen Dizisi	PGIRLA	5	0	-	%52,63	%54,55	-1,9%	20	636	31,8	2
E.Coli Gen Dizisi	PGIRLA	5	1	-	%47,37	%63,64	-16,3%	20	615	30,8	1
E.Coli Gen Dizisi	PGIRLA	5	2	-	%75,79	%63,64	%12,2	20	659	33	2
E.Coli Gen Dizisi	PGIRLA	5	3	-	%72,63	%72,73	-0,1%	20	596	29,8	1
E.Coli Gen Dizisi	PGIRLA	5	4	-	%54,74	%45,45	%9,3	20	606	30,3	2
E.Coli Gen Dizisi	PGIRLA	5	5	-	%64,21	%45,45	%18,8	20	606	30,3	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
E.Coli Gen Dizisi	PGIRLA	5	6	-	%56,25	%50,00	%6,3	20	639	32	1
E.Coli Gen Dizisi	PGIRLA	5	7	-	%54,17	%50,00	%4,2	20	612	30,6	2
E.Coli Gen Dizisi	PGIRLA	5	8	-	%75,00	%40,00	%35	20	595	29,8	1
E.Coli Gen Dizisi	PGIRLA	5	9	-	%57,29	%50,00	%7,3	20	626	31,3	2
E.Coli Gen Dizisi	SIA	1	0	-	%100	%90,91	%9,1	28	65	2,3	3
E.Coli Gen Dizisi	SIA	1	1	-	%100	%90,91	%9,1	34	58	1,7	3
E.Coli Gen Dizisi	SIA	1	2	-	%100	%63,64	%36,4	30	62	2,1	3
E.Coli Gen Dizisi	SIA	1	3	-	%100	%72,73	%27,3	33	53	1,6	3
E.Coli Gen Dizisi	SIA	1	4	-	%100	%72,73	%27,3	33	57	1,7	3
E.Coli Gen Dizisi	SIA	1	5	-	%100	%72,73	%27,3	32	93	2,9	3
E.Coli Gen Dizisi	SIA	1	6	-	%100	%40,00	%60	28	73	2,6	3
E.Coli Gen Dizisi	SIA	1	7	-	%100	%60,00	%40	29	70	2,4	3
E.Coli Gen Dizisi	SIA	1	8	-	%100	%60,00	%40	31	85	2,7	3
E.Coli Gen Dizisi	SIA	1	9	-	%100	%100	%0	30	68	2,3	3
E.Coli Gen Dizisi	SIA	2	0	-	%100	%90,91	%9,1	27	74	2,7	3
E.Coli Gen Dizisi	SIA	2	1	-	%100	%90,91	%9,1	30	46	1,5	3
E.Coli Gen Dizisi	SIA	2	2	-	%100	%90,91	%9,1	22	68	3,1	2
E.Coli Gen Dizisi	SIA	2	3	-	%100	%81,82	%18,2	29	69	2,4	3
E.Coli Gen Dizisi	SIA	2	4	-	%100	%81,82	%18,2	30	68	2,3	3
E.Coli Gen Dizisi	SIA	2	5	-	%100	%63,64	%36,4	29	81	2,8	3
E.Coli Gen Dizisi	SIA	2	6	-	%100	%60,00	%40	26	71	2,7	3
E.Coli Gen Dizisi	SIA	2	7	-	%100	%80,00	%20	28	71	2,5	3
E.Coli Gen Dizisi	SIA	2	8	-	%100	%60,00	%40	31	68	2,2	3
E.Coli Gen Dizisi	SIA	2	9	-	%100	%80,00	%20	29	83	2,9	3
E.Coli Gen Dizisi	SIA	3	0	-	%100	%90,91	%9,1	26	79	3	2
E.Coli Gen Dizisi	SIA	3	1	-	%100	%90,91	%9,1	29	71	2,4	3
E.Coli Gen Dizisi	SIA	3	2	-	%100	%90,91	%9,1	28	70	2,5	2
E.Coli Gen Dizisi	SIA	3	3	-	%100	%81,82	%18,2	30	75	2,5	3
E.Coli Gen Dizisi	SIA	3	4	-	%100	%72,73	%27,3	30	74	2,5	3
E.Coli Gen Dizisi	SIA	3	5	-	%100	%63,64	%36,4	27	79	2,9	3
E.Coli Gen Dizisi	SIA	3	6	-	%100	%80,00	%20	26	73	2,8	2
E.Coli Gen Dizisi	SIA	3	7	-	%100	%50,00	%50	28	64	2,3	3
E.Coli Gen Dizisi	SIA	3	8	-	%100	%80,00	%20	31	87	2,8	3
E.Coli Gen Dizisi	SIA	3	9	-	%100	%50,00	%50	26	68	2,6	2
E.Coli Gen Dizisi	SIA	4	0	-	%100	%90,91	%9,1	25	64	2,6	3
E.Coli Gen Dizisi	SIA	4	1	-	%100	%72,73	%27,3	34	62	1,8	3
E.Coli Gen Dizisi	SIA	4	2	-	%100	%81,82	%18,2	28	66	2,4	3
E.Coli Gen Dizisi	SIA	4	3	-	%100	%63,64	%36,4	29	75	2,6	3
E.Coli Gen Dizisi	SIA	4	4	-	%100	%72,73	%27,3	30	62	2,1	3
E.Coli Gen Dizisi	SIA	4	5	-	%100	%81,82	%18,2	33	68	2,1	3
E.Coli Gen Dizisi	SIA	4	6	-	%100	%80,00	%20	30	66	2,2	3
E.Coli Gen Dizisi	SIA	4	7	-	%100	%60,00	%40	26	63	2,4	2
E.Coli Gen Dizisi	SIA	4	8	-	%100	%40,00	%60	34	61	1,8	3
E.Coli Gen Dizisi	SIA	4	9	-	%100	%70,00	%30	27	57	2,1	2
E.Coli Gen Dizisi	SIA	5	0	-	%100	%63,64	%36,4	25	78	3,1	3
E.Coli Gen Dizisi	SIA	5	1	-	%100	%81,82	%18,2	29	75	2,6	3
E.Coli Gen Dizisi	SIA	5	2	-	%100	%100	%0	28	72	2,6	3
E.Coli Gen Dizisi	SIA	5	3	-	%100	%72,73	%27,3	34	85	2,5	4
E.Coli Gen Dizisi	SIA	5	4	-	%100	%72,73	%27,3	31	103	3,3	3
E.Coli Gen Dizisi	SIA	5	5	-	%100	%54,55	%45,5	28	70	2,5	4
E.Coli Gen Dizisi	SIA	5	6	-	%100	%80,00	%20	27	65	2,4	4
E.Coli Gen Dizisi	SIA	5	7	-	%100	%80,00	%20	26	61	2,3	3
E.Coli Gen Dizisi	SIA	5	8	-	%100	%70,00	%30	33	63	1,9	3
E.Coli Gen Dizisi	SIA	5	9	-	%100	%80,00	%20	28	71	2,5	3
Hayvanat Bahçesi	ABCMiner	1	0	29.188	%94,44	%90,91	%3,5	6	8	1,3	32,3
Hayvanat Bahçesi	ABCMiner	1	1	26.289	%94,51	%90,00	%4,5	6	7	1,2	26,1
Hayvanat Bahçesi	ABCMiner	1	2	38.660	%95,60	%80,00	%15,6	6	7	1,2	33,1
Hayvanat Bahçesi	ABCMiner	1	3	27.284	%93,41	%100	-6,6%	6	8	1,3	32,4
Hayvanat Bahçesi	ABCMiner	1	4	23.489	%93,41	%100	-6,6%	6	7	1,2	22,7
Hayvanat Bahçesi	ABCMiner	1	5	23.349	%94,51	%90,00	%4,5	6	6	1	20
Hayvanat Bahçesi	ABCMiner	1	6	23.575	%93,41	%100	-6,6%	6	6	1	24,7
Hayvanat Bahçesi	ABCMiner	1	7	25.116	%94,51	%90,00	%4,5	6	6	1	24,1
Hayvanat Bahçesi	ABCMiner	1	8	23.246	%93,41	%100	-6,6%	6	7	1,2	21,1
Hayvanat Bahçesi	ABCMiner	1	9	30.316	%94,51	%90,00	%4,5	6	7	1,2	42,5
Hayvanat Bahçesi	ABCMiner	2	0	25.049	%94,44	%90,91	%3,5	6	6	1	28,4
Hayvanat Bahçesi	ABCMiner	2	1	26.929	%95,60	%80,00	%15,6	6	7	1,2	30,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hayvanat Bahçesi	ABCMiner	2	2	23.221	%95,60	%80,00	%15,6	6	7	1,2	25,1
Hayvanat Bahçesi	ABCMiner	2	3	25.240	%93,41	%90,00	%3,4	6	6	1	26,7
Hayvanat Bahçesi	ABCMiner	2	4	24.430	%93,41	%90,00	%3,4	6	8	1,3	26,6
Hayvanat Bahçesi	ABCMiner	2	5	30.079	%93,41	%80,00	%13,4	6	8	1,3	37,9
Hayvanat Bahçesi	ABCMiner	2	6	22.175	%92,31	%100	-7,7%	6	6	1	24,6
Hayvanat Bahçesi	ABCMiner	2	7	26.802	%94,51	%90,00	%4,5	6	6	1	33,6
Hayvanat Bahçesi	ABCMiner	2	8	26.128	%93,41	%100	-6,6%	6	6	1	29,6
Hayvanat Bahçesi	ABCMiner	2	9	27.039	%94,51	%90,00	%4,5	6	6	1	34,1
Hayvanat Bahçesi	ABCMiner	3	0	27.229	%94,44	%90,91	%3,5	6	6	1	36,7
Hayvanat Bahçesi	ABCMiner	3	1	24.494	%95,60	%80,00	%15,6	6	7	1,2	22,4
Hayvanat Bahçesi	ABCMiner	3	2	38.171	%95,60	%70,00	%25,6	6	8	1,3	30,5
Hayvanat Bahçesi	ABCMiner	3	3	24.470	%93,41	%100	-6,6%	6	6	1	24,4
Hayvanat Bahçesi	ABCMiner	3	4	22.081	%93,41	%100	-6,6%	6	6	1	21,1
Hayvanat Bahçesi	ABCMiner	3	5	24.880	%94,51	%90,00	%4,5	6	6	1	23,9
Hayvanat Bahçesi	ABCMiner	3	6	23.567	%93,41	%100	-6,6%	6	6	1	25,5
Hayvanat Bahçesi	ABCMiner	3	7	26.669	%94,51	%90,00	%4,5	6	6	1	30,2
Hayvanat Bahçesi	ABCMiner	3	8	32.664	%93,41	%100	-6,6%	6	8	1,3	44,9
Hayvanat Bahçesi	ABCMiner	3	9	24.016	%94,51	%90,00	%4,5	6	6	1	25,1
Hayvanat Bahçesi	ABCMiner	4	0	26.756	%94,44	%90,91	%3,5	6	8	1,3	31,4
Hayvanat Bahçesi	ABCMiner	4	1	30.305	%94,51	%90,00	%4,5	6	6	1	37,1
Hayvanat Bahçesi	ABCMiner	4	2	25.358	%95,60	%70,00	%25,6	6	8	1,3	27
Hayvanat Bahçesi	ABCMiner	4	3	25.662	%93,41	%90,00	%3,4	6	7	1,2	29
Hayvanat Bahçesi	ABCMiner	4	4	26.237	%93,41	%100	-6,6%	6	6	1	30,6
Hayvanat Bahçesi	ABCMiner	4	5	24.261	%94,51	%80,00	%14,5	6	8	1,3	25,8
Hayvanat Bahçesi	ABCMiner	4	6	30.033	%93,41	%90,00	%3,4	6	7	1,2	41,9
Hayvanat Bahçesi	ABCMiner	4	7	23.643	%94,51	%90,00	%4,5	6	7	1,2	23
Hayvanat Bahçesi	ABCMiner	4	8	28.991	%93,41	%100	-6,6%	6	6	1	38,6
Hayvanat Bahçesi	ABCMiner	4	9	24.971	%94,51	%90,00	%4,5	6	6	1	25,5
Hayvanat Bahçesi	ABCMiner	5	0	22.939	%94,44	%90,91	%3,5	6	6	1	24,5
Hayvanat Bahçesi	ABCMiner	5	1	31.407	%95,60	%80,00	%15,6	6	7	1,2	30,9
Hayvanat Bahçesi	ABCMiner	5	2	24.619	%95,60	%80,00	%15,6	6	7	1,2	26,9
Hayvanat Bahçesi	ABCMiner	5	3	31.991	%93,41	%100	-6,6%	6	6	1	45,2
Hayvanat Bahçesi	ABCMiner	5	4	26.466	%93,41	%100	-6,6%	6	7	1,2	24,2
Hayvanat Bahçesi	ABCMiner	5	5	27.518	%94,51	%90,00	%4,5	6	7	1,2	32,7
Hayvanat Bahçesi	ABCMiner	5	6	25.187	%93,41	%100	-6,6%	6	9	1,5	29,4
Hayvanat Bahçesi	ABCMiner	5	7	25.782	%94,51	%90,00	%4,5	6	6	1	26
Hayvanat Bahçesi	ABCMiner	5	8	26.782	%93,41	%100	-6,6%	6	6	1	30,3
Hayvanat Bahçesi	ABCMiner	5	9	43.096	%94,51	%90,00	%4,5	6	6	1	75,9
Hayvanat Bahçesi	C4.5	-	1	-	%98,89	%100	-1,1%	8	19	2,4	0,3
Hayvanat Bahçesi	C4.5	-	2	-	%97,80	%90,00	%7,8	8	20	2,5	0,3
Hayvanat Bahçesi	C4.5	-	3	-	%98,90	%80,00	%18,9	8	21	2,6	0,3
Hayvanat Bahçesi	C4.5	-	4	-	%98,90	%100	-1,1%	8	19	2,4	0,3
Hayvanat Bahçesi	C4.5	-	5	-	%98,90	%90,00	%8,9	7	17	2,4	0,3
Hayvanat Bahçesi	C4.5	-	6	-	%97,80	%90,00	%7,8	7	17	2,4	0,3
Hayvanat Bahçesi	C4.5	-	7	-	%98,90	%100	-1,1%	8	17	2,1	0,3
Hayvanat Bahçesi	C4.5	-	8	-	%97,80	%90,00	%7,8	7	16	2,3	0,3
Hayvanat Bahçesi	C4.5	-	9	-	%98,90	%100	-1,1%	8	18	2,3	0,3
Hayvanat Bahçesi	C4.5	-	10	-	%98,90	%100	-1,1%	8	18	2,3	0,3
Hayvanat Bahçesi	CoABCMiner	1	0	110.739	%100	%100	%0	7	30	4,3	1,2
Hayvanat Bahçesi	CoABCMiner	1	1	110.744	%100	%100	%0	7	29	4,1	1,2
Hayvanat Bahçesi	CoABCMiner	1	2	110.772	%100	%80,00	%20	7	25	3,6	1
Hayvanat Bahçesi	CoABCMiner	1	3	110.740	%100	%80,00	%20	7	31	4,4	1
Hayvanat Bahçesi	CoABCMiner	1	4	110.759	%100	%90,00	%10	7	27	3,9	1
Hayvanat Bahçesi	CoABCMiner	1	5	110.739	%100	%100	%0	7	26	3,7	1,3
Hayvanat Bahçesi	CoABCMiner	1	6	110.734	%100	%90,00	%10	7	27	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	1	7	110.747	%100	%100	%0	7	26	3,7	1,1
Hayvanat Bahçesi	CoABCMiner	1	8	110.751	%100	%100	%0	7	28	4	1,1
Hayvanat Bahçesi	CoABCMiner	1	9	110.747	%100	%90,00	%10	7	28	4	1,1
Hayvanat Bahçesi	CoABCMiner	2	0	110.739	%100	%100	%0	8	32	4	1,1
Hayvanat Bahçesi	CoABCMiner	2	1	110.744	%100	%100	%0	7	27	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	2	2	110.767	%100	%90,00	%10	7	26	3,7	1
Hayvanat Bahçesi	CoABCMiner	2	3	110.757	%100	%90,00	%10	7	29	4,1	1
Hayvanat Bahçesi	CoABCMiner	2	4	110.753	%100	%80,00	%20	7	31	4,4	1,1
Hayvanat Bahçesi	CoABCMiner	2	5	110.747	%100	%100	%0	7	28	4	1
Hayvanat Bahçesi	CoABCMiner	2	6	110.757	%100	%90,00	%10	7	28	4	1
Hayvanat Bahçesi	CoABCMiner	2	7	110.748	%100	%100	%0	7	28	4	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hayvanat Bahçesi	CoABCMiner	2	8	110.740	%100	%100	%0	7	29	4,1	1
Hayvanat Bahçesi	CoABCMiner	2	9	110.747	%100	%100	%0	7	30	4,3	0,9
Hayvanat Bahçesi	CoABCMiner	3	0	110.754	%100	%100	%0	7	27	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	3	1	110.747	%100	%100	%0	7	31	4,4	1,1
Hayvanat Bahçesi	CoABCMiner	3	2	110.772	%100	%90,00	%10	7	26	3,7	1
Hayvanat Bahçesi	CoABCMiner	3	3	110.746	%100	%80,00	%20	7	30	4,3	1,1
Hayvanat Bahçesi	CoABCMiner	3	4	110.758	%100	%70,00	%30	7	28	4	1
Hayvanat Bahçesi	CoABCMiner	3	5	110.762	%100	%100	%0	7	28	4	1,2
Hayvanat Bahçesi	CoABCMiner	3	6	110.751	%100	%90,00	%10	8	31	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	3	7	110.744	%100	%100	%0	7	31	4,4	1,1
Hayvanat Bahçesi	CoABCMiner	3	8	110.734	%100	%100	%0	7	31	4,4	1
Hayvanat Bahçesi	CoABCMiner	3	9	110.742	%100	%100	%0	7	30	4,3	1
Hayvanat Bahçesi	CoABCMiner	4	0	110.750	%100	%100	%0	7	30	4,3	1
Hayvanat Bahçesi	CoABCMiner	4	1	110.737	%100	%100	%0	7	32	4,6	1
Hayvanat Bahçesi	CoABCMiner	4	2	110.758	%100	%80,00	%20	7	29	4,1	1,2
Hayvanat Bahçesi	CoABCMiner	4	3	110.761	%100	%90,00	%10	7	31	4,4	1,2
Hayvanat Bahçesi	CoABCMiner	4	4	110.744	%100	%80,00	%20	8	31	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	4	5	110.745	%100	%100	%0	7	29	4,1	1,1
Hayvanat Bahçesi	CoABCMiner	4	6	110.749	%100	%90,00	%10	7	28	4	1,1
Hayvanat Bahçesi	CoABCMiner	4	7	110.745	%100	%100	%0	7	30	4,3	1
Hayvanat Bahçesi	CoABCMiner	4	8	110.738	%100	%100	%0	7	29	4,1	1,2
Hayvanat Bahçesi	CoABCMiner	4	9	110.735	%100	%100	%0	7	31	4,4	1,1
Hayvanat Bahçesi	CoABCMiner	5	0	110.756	%100	%90,91	%9,1	7	31	4,4	1,1
Hayvanat Bahçesi	CoABCMiner	5	1	110.752	%100	%100	%0	7	27	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	5	2	110.763	%100	%80,00	%20	7	27	3,9	1
Hayvanat Bahçesi	CoABCMiner	5	3	110.752	%100	%80,00	%20	7	29	4,1	1,2
Hayvanat Bahçesi	CoABCMiner	5	4	110.762	%100	%100	%0	7	26	3,7	1,2
Hayvanat Bahçesi	CoABCMiner	5	5	110.752	%100	%100	%0	7	27	3,9	1,1
Hayvanat Bahçesi	CoABCMiner	5	6	110.755	%100	%90,00	%10	7	28	4	1
Hayvanat Bahçesi	CoABCMiner	5	7	110.749	%100	%100	%0	7	31	4,4	1
Hayvanat Bahçesi	CoABCMiner	5	8	110.749	%100	%100	%0	7	30	4,3	1,1
Hayvanat Bahçesi	CoABCMiner	5	9	110.736	%100	%100	%0	7	31	4,4	1,1
Hayvanat Bahçesi	CORE	1	0	1.965.181	%100	%100	%0	7	39	5,6	27
Hayvanat Bahçesi	CORE	1	1	1.964.241	%98,90	%100	-1,1%	8	43	5,4	27
Hayvanat Bahçesi	CORE	1	2	1.965.802	%98,90	%80,00	%18,9	9	47	5,2	31,1
Hayvanat Bahçesi	CORE	1	3	1.966.724	%98,90	%90,00	%8,9	12	62	5,2	29,3
Hayvanat Bahçesi	CORE	1	4	1.965.322	%100	%80,00	%20	8	51	6,4	29,4
Hayvanat Bahçesi	CORE	1	5	1.965.061	%100	%100	%0	7	32	4,6	25,9
Hayvanat Bahçesi	CORE	1	6	1.966.135	%100	%80,00	%20	10	55	5,5	28,6
Hayvanat Bahçesi	CORE	1	7	1.965.315	%98,90	%90,00	%8,9	7	31	4,4	26,2
Hayvanat Bahçesi	CORE	1	8	1.966.928	%100	%100	%0	8	43	5,4	26,4
Hayvanat Bahçesi	CORE	1	9	1.965.665	%100	%100	%0	7	35	5	26,5
Hayvanat Bahçesi	CORE	2	0	-	%100	%100	%0	8	49	6,1	29,4
Hayvanat Bahçesi	CORE	2	1	-	%98,90	%100	-1,1%	10	60	6	29,9
Hayvanat Bahçesi	CORE	2	2	-	%100	%90,00	%10	7	30	4,3	29,9
Hayvanat Bahçesi	CORE	2	3	-	%100	%90,00	%10	8	48	6	30,6
Hayvanat Bahçesi	CORE	2	4	-	%97,80	%80,00	%17,8	10	53	5,3	31,1
Hayvanat Bahçesi	CORE	2	5	-	%100	%100	%0	7	43	6,1	29,4
Hayvanat Bahçesi	CORE	2	6	-	%100	%90,00	%10	7	34	4,9	30,9
Hayvanat Bahçesi	CORE	2	7	-	%100	%100	%0	7	38	5,4	32,3
Hayvanat Bahçesi	CORE	2	8	-	%100	%100	%0	7	40	5,7	29,7
Hayvanat Bahçesi	CORE	2	9	-	%100	%90,00	%10	8	46	5,8	30,2
Hayvanat Bahçesi	CORE	3	0	-	%100	%90,91	%9,1	7	36	5,1	30,8
Hayvanat Bahçesi	CORE	3	1	-	%97,80	%90,00	%7,8	8	38	4,8	27,7
Hayvanat Bahçesi	CORE	3	2	-	%100	%90,00	%10	7	38	5,4	29
Hayvanat Bahçesi	CORE	3	3	-	%100	%90,00	%10	13	56	4,3	28,9
Hayvanat Bahçesi	CORE	3	4	-	%100	%80,00	%20	7	32	4,6	28,2
Hayvanat Bahçesi	CORE	3	5	-	%100	%100	%0	7	39	5,6	28,9
Hayvanat Bahçesi	CORE	3	6	-	%100	%80,00	%20	7	39	5,6	30,2
Hayvanat Bahçesi	CORE	3	7	-	%98,90	%90,00	%8,9	7	36	5,1	27
Hayvanat Bahçesi	CORE	3	8	-	%100	%100	%0	10	50	5	26,9
Hayvanat Bahçesi	CORE	3	9	-	%100	%100	%0	7	34	4,9	27,2
Hayvanat Bahçesi	CORE	4	0	-	%100	%100	%0	8	52	6,5	28,4
Hayvanat Bahçesi	CORE	4	1	-	%100	%100	%0	7	36	5,1	29,2
Hayvanat Bahçesi	CORE	4	2	-	%100	%80,00	%20	13	70	5,4	30,3
Hayvanat Bahçesi	CORE	4	3	-	%100	%100	%0	8	46	5,8	32,6

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hayvanat Bahçesi	CORE	4	4	-	%100	%90,00	%10	13	69	5,3	29,5
Hayvanat Bahçesi	CORE	4	5	-	%100	%100	%0	7	42	6	29,6
Hayvanat Bahçesi	CORE	4	6	-	%100	%90,00	%10	7	31	4,4	30,8
Hayvanat Bahçesi	CORE	4	7	-	%100	%100	%0	7	38	5,4	30,9
Hayvanat Bahçesi	CORE	4	8	-	%100	%100	%0	7	36	5,1	31,2
Hayvanat Bahçesi	CORE	4	9	-	%100	%100	%0	7	38	5,4	29,2
Hayvanat Bahçesi	CORE	5	0	-	%100	%90,91	%9,1	9	48	5,3	31,8
Hayvanat Bahçesi	CORE	5	1	-	%100	%90,00	%10	7	31	4,4	28,1
Hayvanat Bahçesi	CORE	5	2	-	%100	%90,00	%10	7	37	5,3	31,9
Hayvanat Bahçesi	CORE	5	3	-	%100	%90,00	%10	7	37	5,3	30,8
Hayvanat Bahçesi	CORE	5	4	-	%100	%90,00	%10	7	32	4,6	28,8
Hayvanat Bahçesi	CORE	5	5	-	%100	%90,00	%10	8	48	6	30,4
Hayvanat Bahçesi	CORE	5	6	-	%100	%100	%0	7	39	5,6	29,6
Hayvanat Bahçesi	CORE	5	7	-	%100	%100	%0	13	71	5,5	36,7
Hayvanat Bahçesi	CORE	5	8	-	%100	%100	%0	7	37	5,3	32,2
Hayvanat Bahçesi	CORE	5	9	-	%100	%100	%0	7	40	5,7	35,2
Hayvanat Bahçesi	HIDER	1	0	-	%96,70	%90,90	%5,8	6	9	1,5	3
Hayvanat Bahçesi	HIDER	1	1	-	%95,60	%90,00	%5,6	6	9	1,5	4
Hayvanat Bahçesi	HIDER	1	2	-	%96,70	%80,00	%16,7	6	10	1,7	3
Hayvanat Bahçesi	HIDER	1	3	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	1	4	-	%95,60	%90,00	%5,6	6	11	1,8	3
Hayvanat Bahçesi	HIDER	1	5	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	1	6	-	%100	%90,00	%10	7	8	1,1	4
Hayvanat Bahçesi	HIDER	1	7	-	%100	%100	%0	7	9	1,3	3
Hayvanat Bahçesi	HIDER	1	8	-	%95,60	%100	-4,4%	6	8	1,3	4
Hayvanat Bahçesi	HIDER	1	9	-	%96,70	%90,00	%6,7	6	9	1,5	3
Hayvanat Bahçesi	HIDER	2	0	-	%97,80	%100	-2,2%	7	13	1,9	3
Hayvanat Bahçesi	HIDER	2	1	-	%95,60	%90,00	%5,6	6	12	2	4
Hayvanat Bahçesi	HIDER	2	2	-	%96,70	%80,00	%16,7	6	9	1,5	3
Hayvanat Bahçesi	HIDER	2	3	-	%93,40	%90,00	%3,4	6	9	1,5	4
Hayvanat Bahçesi	HIDER	2	4	-	%93,40	%80,00	%13,4	6	11	1,8	3
Hayvanat Bahçesi	HIDER	2	5	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	2	6	-	%100	%90,00	%10	7	8	1,1	4
Hayvanat Bahçesi	HIDER	2	7	-	%95,60	%100	-4,4%	6	9	1,5	3
Hayvanat Bahçesi	HIDER	2	8	-	%95,60	%100	-4,4%	6	9	1,5	4
Hayvanat Bahçesi	HIDER	2	9	-	%95,60	%90,00	%5,6	6	8	1,3	3
Hayvanat Bahçesi	HIDER	3	0	-	%95,60	%90,90	%4,7	6	9	1,5	3
Hayvanat Bahçesi	HIDER	3	1	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	3	2	-	%95,60	%70,00	%25,6	6	11	1,8	3
Hayvanat Bahçesi	HIDER	3	3	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	3	4	-	%95,60	%90,00	%5,6	6	9	1,5	3
Hayvanat Bahçesi	HIDER	3	5	-	%94,50	%80,00	%14,5	6	9	1,5	4
Hayvanat Bahçesi	HIDER	3	6	-	%98,90	%90,00	%8,9	7	10	1,4	4
Hayvanat Bahçesi	HIDER	3	7	-	%95,60	%100	-4,4%	6	9	1,5	3
Hayvanat Bahçesi	HIDER	3	8	-	%95,60	%100	-4,4%	6	11	1,8	4
Hayvanat Bahçesi	HIDER	3	9	-	%93,40	%90,00	%3,4	6	8	1,3	3
Hayvanat Bahçesi	HIDER	4	0	-	%94,40	%90,90	%3,5	6	8	1,3	3
Hayvanat Bahçesi	HIDER	4	1	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	4	2	-	%96,70	%80,00	%16,7	6	9	1,5	3
Hayvanat Bahçesi	HIDER	4	3	-	%95,60	%90,00	%5,6	6	11	1,8	4
Hayvanat Bahçesi	HIDER	4	4	-	%95,60	%90,00	%5,6	6	10	1,7	3
Hayvanat Bahçesi	HIDER	4	5	-	%95,60	%90,00	%5,6	6	9	1,5	4
Hayvanat Bahçesi	HIDER	4	6	-	%100	%90,00	%10	7	8	1,1	4
Hayvanat Bahçesi	HIDER	4	7	-	%98,90	%90,00	%8,9	7	9	1,3	3
Hayvanat Bahçesi	HIDER	4	8	-	%95,60	%100	-4,4%	6	11	1,8	4
Hayvanat Bahçesi	HIDER	4	9	-	%94,50	%90,00	%4,5	6	9	1,5	3
Hayvanat Bahçesi	HIDER	5	0	-	%96,70	%90,90	%5,8	6	9	1,5	3
Hayvanat Bahçesi	HIDER	5	1	-	%95,60	%90,00	%5,6	6	8	1,3	4
Hayvanat Bahçesi	HIDER	5	2	-	%96,70	%80,00	%16,7	6	9	1,5	3
Hayvanat Bahçesi	HIDER	5	3	-	%95,60	%90,00	%5,6	6	10	1,7	4
Hayvanat Bahçesi	HIDER	5	4	-	%95,60	%80,00	%15,6	6	12	2	3
Hayvanat Bahçesi	HIDER	5	5	-	%95,60	%90,00	%5,6	6	9	1,5	4
Hayvanat Bahçesi	HIDER	5	6	-	%93,40	%100	-6,6%	6	8	1,3	4
Hayvanat Bahçesi	HIDER	5	7	-	%93,40	%90,00	%3,4	6	10	1,7	3
Hayvanat Bahçesi	HIDER	5	8	-	%100	%100	%0	7	9	1,3	4
Hayvanat Bahçesi	HIDER	5	9	-	%93,40	%90,00	%3,4	6	8	1,3	3

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hayvanat Bahçesi	LDWPSO	1	0	100.014	%94,44	%90,91	%3,5	6	6	1	145
Hayvanat Bahçesi	LDWPSO	1	1	100.020	%95,60	%80,00	%15,6	6	7	1,2	147,7
Hayvanat Bahçesi	LDWPSO	1	2	100.024	%95,60	%70,00	%25,6	6	9	1,5	148,5
Hayvanat Bahçesi	LDWPSO	1	3	100.014	%93,41	%90,00	%3,4	6	6	1	143,9
Hayvanat Bahçesi	LDWPSO	1	4	100.014	%93,41	%100	-6,6%	6	6	1	146,7
Hayvanat Bahçesi	LDWPSO	1	5	100.026	%94,51	%80,00	%14,5	6	8	1,3	144,1
Hayvanat Bahçesi	LDWPSO	1	6	100.014	%93,41	%100	-6,6%	6	6	1	145,3
Hayvanat Bahçesi	LDWPSO	1	7	100.014	%94,51	%90,00	%4,5	6	6	1	150,1
Hayvanat Bahçesi	LDWPSO	1	8	100.014	%93,41	%100	-6,6%	6	6	1	147,6
Hayvanat Bahçesi	LDWPSO	1	9	100.014	%94,51	%90,00	%4,5	6	6	1	151,3
Hayvanat Bahçesi	LDWPSO	2	0	120.016	%95,56	%100	-4,4%	7	8	1,1	160,5
Hayvanat Bahçesi	LDWPSO	2	1	100.012	%94,51	%80,00	%14,5	6	6	1	149,7
Hayvanat Bahçesi	LDWPSO	2	2	100.010	%94,51	%70,00	%24,5	6	5	0,8	153
Hayvanat Bahçesi	LDWPSO	2	3	120.016	%95,60	%100	-4,4%	7	8	1,1	164
Hayvanat Bahçesi	LDWPSO	2	4	120.016	%95,60	%100	-4,4%	7	8	1,1	163,4
Hayvanat Bahçesi	LDWPSO	2	5	120.016	%95,60	%90,00	%5,6	7	8	1,1	169,6
Hayvanat Bahçesi	LDWPSO	2	6	120.016	%96,70	%90,00	%6,7	7	7	1	165,7
Hayvanat Bahçesi	LDWPSO	2	7	120.016	%95,60	%100	-4,4%	7	8	1,1	164,1
Hayvanat Bahçesi	LDWPSO	2	8	120.016	%95,60	%100	-4,4%	7	8	1,1	164,7
Hayvanat Bahçesi	LDWPSO	2	9	120.016	%95,60	%100	-4,4%	7	8	1,1	162,3
Hayvanat Bahçesi	LDWPSO	3	0	100.015	%94,44	%90,91	%3,5	6	6	1	177,7
Hayvanat Bahçesi	LDWPSO	3	1	100.022	%95,60	%80,00	%15,6	6	7	1,2	155,6
Hayvanat Bahçesi	LDWPSO	3	2	100.016	%94,51	%70,00	%24,5	6	5	0,8	155
Hayvanat Bahçesi	LDWPSO	3	3	100.015	%93,41	%100	-6,6%	6	6	1	181,2
Hayvanat Bahçesi	LDWPSO	3	4	100.015	%93,41	%100	-6,6%	6	6	1	184,6
Hayvanat Bahçesi	LDWPSO	3	5	100.015	%94,51	%90,00	%4,5	6	6	1	183,1
Hayvanat Bahçesi	LDWPSO	3	6	100.017	%93,41	%100	-6,6%	6	6	1	157,1
Hayvanat Bahçesi	LDWPSO	3	7	100.014	%93,41	%90,00	%3,4	6	6	1	175,6
Hayvanat Bahçesi	LDWPSO	3	8	100.015	%93,41	%100	-6,6%	6	6	1	180,5
Hayvanat Bahçesi	LDWPSO	3	9	100.015	%94,51	%90,00	%4,5	6	6	1	178,6
Hayvanat Bahçesi	LDWPSO	4	0	120.026	%93,33	%90,91	%2,4	7	10	1,4	188
Hayvanat Bahçesi	LDWPSO	4	1	120.033	%94,51	%90,00	%4,5	7	9	1,3	166,7
Hayvanat Bahçesi	LDWPSO	4	2	120.024	%94,51	%70,00	%24,5	7	9	1,3	185,7
Hayvanat Bahçesi	LDWPSO	4	3	120.026	%93,41	%100	-6,6%	7	9	1,3	175
Hayvanat Bahçesi	LDWPSO	4	4	140.030	%96,70	%90,00	%6,7	8	11	1,4	186,2
Hayvanat Bahçesi	LDWPSO	4	5	120.018	%94,51	%90,00	%4,5	7	8	1,1	169
Hayvanat Bahçesi	LDWPSO	4	6	140.030	%95,60	%90,00	%5,6	8	11	1,4	198,3
Hayvanat Bahçesi	LDWPSO	4	7	120.024	%94,51	%80,00	%14,5	7	10	1,4	181,5
Hayvanat Bahçesi	LDWPSO	4	8	140.030	%95,60	%100	-4,4%	8	11	1,4	204,5
Hayvanat Bahçesi	LDWPSO	4	9	140.030	%95,60	%100	-4,4%	8	11	1,4	200,2
Hayvanat Bahçesi	LDWPSO	5	0	120.018	%95,56	%100	-4,4%	7	8	1,1	118,1
Hayvanat Bahçesi	LDWPSO	5	1	100.014	%94,51	%80,00	%14,5	6	6	1	115,5
Hayvanat Bahçesi	LDWPSO	5	2	100.014	%94,51	%70,00	%24,5	6	5	0,8	110,2
Hayvanat Bahçesi	LDWPSO	5	3	120.022	%95,60	%100	-4,4%	7	8	1,1	119,5
Hayvanat Bahçesi	LDWPSO	5	4	120.022	%95,60	%100	-4,4%	7	8	1,1	116,4
Hayvanat Bahçesi	LDWPSO	5	5	120.018	%95,60	%90,00	%5,6	7	8	1,1	123,2
Hayvanat Bahçesi	LDWPSO	5	6	120.016	%96,70	%90,00	%6,7	7	7	1	122,9
Hayvanat Bahçesi	LDWPSO	5	7	120.018	%94,51	%90,00	%4,5	7	8	1,1	118,4
Hayvanat Bahçesi	LDWPSO	5	8	120.022	%95,60	%100	-4,4%	7	8	1,1	124,4
Hayvanat Bahçesi	LDWPSO	5	9	120.018	%95,60	%100	-4,4%	7	8	1,1	119,8
Hayvanat Bahçesi	PGIRLA	1	0	-	%93,33	%90,91	%2,4	20	170	8,5	1
Hayvanat Bahçesi	PGIRLA	1	1	-	%95,60	%90,00	%5,6	20	164	8,2	1
Hayvanat Bahçesi	PGIRLA	1	2	-	%91,21	%70,00	%21,2	20	141	7,1	1
Hayvanat Bahçesi	PGIRLA	1	3	-	%91,21	%90,00	%1,2	20	144	7,2	0,6
Hayvanat Bahçesi	PGIRLA	1	4	-	%94,51	%100	-5,5%	20	180	9	1
Hayvanat Bahçesi	PGIRLA	1	5	-	%93,41	%90,00	%3,4	20	156	7,8	1
Hayvanat Bahçesi	PGIRLA	1	6	-	%91,21	%90,00	%1,2	20	171	8,6	1
Hayvanat Bahçesi	PGIRLA	1	7	-	%92,31	%90,00	%2,3	20	166	8,3	1
Hayvanat Bahçesi	PGIRLA	1	8	-	%92,31	%100	-7,7%	20	166	8,3	0,4
Hayvanat Bahçesi	PGIRLA	1	9	-	%91,21	%90,00	%1,2	20	161	8,1	1
Hayvanat Bahçesi	PGIRLA	2	0	-	%91,11	%90,91	%0,2	20	143	7,2	1
Hayvanat Bahçesi	PGIRLA	2	1	-	%93,41	%80,00	%13,4	20	153	7,7	1
Hayvanat Bahçesi	PGIRLA	2	2	-	%94,51	%70,00	%24,5	20	170	8,5	1
Hayvanat Bahçesi	PGIRLA	2	3	-	%92,31	%90,00	%2,3	20	156	7,8	0,6
Hayvanat Bahçesi	PGIRLA	2	4	-	%92,31	%90,00	%2,3	20	152	7,6	1
Hayvanat Bahçesi	PGIRLA	2	5	-	%95,60	%80,00	%15,6	20	154	7,7	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hayvanat Bahçesi	PGIRLA	2	6	-	%97,80	%100	-2,2%	20	178	8,9	1
Hayvanat Bahçesi	PGIRLA	2	7	-	%98,90	%90,00	%8,9	20	172	8,6	1
Hayvanat Bahçesi	PGIRLA	2	8	-	%92,31	%100	-7,7%	20	167	8,4	0,4
Hayvanat Bahçesi	PGIRLA	2	9	-	%90,11	%90,00	%0,1	20	159	8	1
Hayvanat Bahçesi	PGIRLA	3	0	-	%94,44	%90,91	%3,5	20	154	7,7	1
Hayvanat Bahçesi	PGIRLA	3	1	-	%96,70	%90,00	%6,7	20	170	8,5	1
Hayvanat Bahçesi	PGIRLA	3	2	-	%93,41	%80,00	%13,4	20	160	8	1
Hayvanat Bahçesi	PGIRLA	3	3	-	%89,01	%90,00	-1,0%	20	160	8	0,6
Hayvanat Bahçesi	PGIRLA	3	4	-	%95,60	%80,00	%15,6	20	151	7,6	1
Hayvanat Bahçesi	PGIRLA	3	5	-	%92,31	%80,00	%12,3	20	161	8,1	1
Hayvanat Bahçesi	PGIRLA	3	6	-	%97,80	%100	-2,2%	20	168	8,4	1
Hayvanat Bahçesi	PGIRLA	3	7	-	%91,21	%90,00	%1,2	20	167	8,4	1
Hayvanat Bahçesi	PGIRLA	3	8	-	%94,51	%80,00	%14,5	20	148	7,4	0,4
Hayvanat Bahçesi	PGIRLA	3	9	-	%95,60	%100	-4,4%	20	166	8,3	1
Hayvanat Bahçesi	PGIRLA	4	0	-	%97,78	%100	-2,2%	20	170	8,5	1
Hayvanat Bahçesi	PGIRLA	4	1	-	%92,31	%70,00	%22,3	20	133	6,7	1
Hayvanat Bahçesi	PGIRLA	4	2	-	%95,60	%80,00	%15,6	20	149	7,5	1
Hayvanat Bahçesi	PGIRLA	4	3	-	%95,60	%90,00	%5,6	20	173	8,7	0,6
Hayvanat Bahçesi	PGIRLA	4	4	-	%96,70	%90,00	%6,7	20	171	8,6	1
Hayvanat Bahçesi	PGIRLA	4	5	-	%90,11	%80,00	%10,1	20	172	8,6	1
Hayvanat Bahçesi	PGIRLA	4	6	-	%93,41	%90,00	%3,4	20	145	7,3	1
Hayvanat Bahçesi	PGIRLA	4	7	-	%92,31	%100	-7,7%	20	165	8,3	1
Hayvanat Bahçesi	PGIRLA	4	8	-	%94,51	%100	-5,5%	20	162	8,1	0,4
Hayvanat Bahçesi	PGIRLA	4	9	-	%94,51	%80,00	%14,5	20	164	8,2	1
Hayvanat Bahçesi	PGIRLA	5	0	-	%94,44	%90,91	%3,5	20	155	7,8	1
Hayvanat Bahçesi	PGIRLA	5	1	-	%94,51	%80,00	%14,5	20	151	7,6	1
Hayvanat Bahçesi	PGIRLA	5	2	-	%92,31	%80,00	%12,3	20	161	8,1	1
Hayvanat Bahçesi	PGIRLA	5	3	-	%91,21	%90,00	%1,2	20	164	8,2	0,6
Hayvanat Bahçesi	PGIRLA	5	4	-	%92,31	%70,00	%22,3	20	173	8,7	1
Hayvanat Bahçesi	PGIRLA	5	5	-	%95,60	%80,00	%15,6	20	176	8,8	1
Hayvanat Bahçesi	PGIRLA	5	6	-	%98,90	%90,00	%8,9	20	153	7,7	1
Hayvanat Bahçesi	PGIRLA	5	7	-	%94,51	%90,00	%4,5	20	167	8,4	1
Hayvanat Bahçesi	PGIRLA	5	8	-	%93,41	%100	-6,6%	20	153	7,7	0,4
Hayvanat Bahçesi	PGIRLA	5	9	-	%95,60	%90,00	%5,6	20	164	8,2	1
Hayvanat Bahçesi	SIA	1	0	-	%100	%100	%0	10	52	5,2	1
Hayvanat Bahçesi	SIA	1	1	-	%100	%100	%0	11	59	5,4	1
Hayvanat Bahçesi	SIA	1	2	-	%100	%80,00	%20	9	45	5	1
Hayvanat Bahçesi	SIA	1	3	-	%100	%90,00	%10	10	40	4	1
Hayvanat Bahçesi	SIA	1	4	-	%100	%100	%0	9	39	4,3	1
Hayvanat Bahçesi	SIA	1	5	-	%100	%100	%0	11	66	6	1
Hayvanat Bahçesi	SIA	1	6	-	%100	%90,00	%10	10	55	5,5	1
Hayvanat Bahçesi	SIA	1	7	-	%100	%100	%0	10	49	4,9	1
Hayvanat Bahçesi	SIA	1	8	-	%100	%100	%0	11	54	4,9	1
Hayvanat Bahçesi	SIA	1	9	-	%100	%100	%0	10	55	5,5	1
Hayvanat Bahçesi	SIA	2	0	-	%100	%100	%0	10	34	3,4	1
Hayvanat Bahçesi	SIA	2	1	-	%100	%100	%0	11	58	5,3	1
Hayvanat Bahçesi	SIA	2	2	-	%100	%90,00	%10	10	38	3,8	1
Hayvanat Bahçesi	SIA	2	3	-	%100	%90,00	%10	10	49	4,9	1
Hayvanat Bahçesi	SIA	2	4	-	%100	%80,00	%20	9	43	4,8	1
Hayvanat Bahçesi	SIA	2	5	-	%100	%100	%0	10	56	5,6	1
Hayvanat Bahçesi	SIA	2	6	-	%100	%90,00	%10	9	54	6	1
Hayvanat Bahçesi	SIA	2	7	-	%100	%100	%0	11	41	3,7	1
Hayvanat Bahçesi	SIA	2	8	-	%100	%100	%0	10	59	5,9	1
Hayvanat Bahçesi	SIA	2	9	-	%100	%100	%0	12	47	3,9	1
Hayvanat Bahçesi	SIA	3	0	-	%100	%100	%0	9	49	5,4	1
Hayvanat Bahçesi	SIA	3	1	-	%100	%100	%0	10	44	4,4	1
Hayvanat Bahçesi	SIA	3	2	-	%100	%80,00	%20	8	54	6,8	1
Hayvanat Bahçesi	SIA	3	3	-	%100	%100	%0	9	68	7,6	1
Hayvanat Bahçesi	SIA	3	4	-	%100	%100	%0	10	47	4,7	1
Hayvanat Bahçesi	SIA	3	5	-	%100	%100	%0	11	60	5,5	1
Hayvanat Bahçesi	SIA	3	6	-	%100	%90,00	%10	9	47	5,2	1
Hayvanat Bahçesi	SIA	3	7	-	%100	%100	%0	11	52	4,7	1
Hayvanat Bahçesi	SIA	3	8	-	%100	%100	%0	11	44	4	1
Hayvanat Bahçesi	SIA	3	9	-	%100	%100	%0	9	37	4,1	1
Hayvanat Bahçesi	SIA	4	0	-	%100	%100	%0	10	55	5,5	1
Hayvanat Bahçesi	SIA	4	1	-	%100	%100	%0	11	47	4,3	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hayvanat Bahçesi	SIA	4	2	-	%100	%80,00	%20	10	51	5,1	1
Hayvanat Bahçesi	SIA	4	3	-	%100	%100	%0	10	41	4,1	1
Hayvanat Bahçesi	SIA	4	4	-	%100	%70,00	%30	11	44	4	1
Hayvanat Bahçesi	SIA	4	5	-	%100	%100	%0	10	48	4,8	1
Hayvanat Bahçesi	SIA	4	6	-	%100	%90,00	%10	9	48	5,3	1
Hayvanat Bahçesi	SIA	4	7	-	%100	%100	%0	10	61	6,1	1
Hayvanat Bahçesi	SIA	4	8	-	%100	%100	%0	10	53	5,3	1
Hayvanat Bahçesi	SIA	4	9	-	%100	%90,00	%10	10	35	3,5	1
Hayvanat Bahçesi	SIA	5	0	-	%100	%100	%0	9	68	7,6	1
Hayvanat Bahçesi	SIA	5	1	-	%100	%100	%0	11	52	4,7	1
Hayvanat Bahçesi	SIA	5	2	-	%100	%90,00	%10	8	44	5,5	1
Hayvanat Bahçesi	SIA	5	3	-	%100	%90,00	%10	10	39	3,9	1
Hayvanat Bahçesi	SIA	5	4	-	%100	%80,00	%20	9	47	5,2	1
Hayvanat Bahçesi	SIA	5	5	-	%100	%100	%0	10	51	5,1	1
Hayvanat Bahçesi	SIA	5	6	-	%100	%90,00	%10	9	72	8	1
Hayvanat Bahçesi	SIA	5	7	-	%100	%100	%0	10	51	5,1	1
Hayvanat Bahçesi	SIA	5	8	-	%100	%100	%0	10	48	4,8	1
Hayvanat Bahçesi	SIA	5	9	-	%100	%100	%0	10	41	4,1	1
Hepatit	ABCMiner	1	0	80.544	%92,09	%81,25	%10,8	5	16	3,2	215,8
Hepatit	ABCMiner	1	1	60.433	%92,09	%68,75	%23,3	4	12	3	189,7
Hepatit	ABCMiner	1	2	80.555	%89,93	%81,25	%8,7	5	14	2,8	225,3
Hepatit	ABCMiner	1	3	80.522	%91,37	%81,25	%10,1	5	13	2,6	219,8
Hepatit	ABCMiner	1	4	60.404	%92,81	%75,00	%17,8	4	11	2,8	214,3
Hepatit	ABCMiner	1	5	80.579	%95,00	%93,33	%1,7	5	15	3	241,2
Hepatit	ABCMiner	1	6	60.614	%90,71	%80,00	%10,7	4	15	3,8	223,5
Hepatit	ABCMiner	1	7	80.578	%95,00	%66,67	%28,3	5	14	2,8	218,7
Hepatit	ABCMiner	1	8	100.761	%94,29	%86,67	%7,6	6	19	3,2	250,6
Hepatit	ABCMiner	1	9	80.558	%91,43	%80,00	%11,4	5	11	2,2	208,9
Hepatit	ABCMiner	2	0	80.537	%90,65	%75,00	%15,6	5	12	2,4	236,5
Hepatit	ABCMiner	2	1	80.559	%92,09	%68,75	%23,3	5	14	2,8	229
Hepatit	ABCMiner	2	2	80.576	%91,37	%81,25	%10,1	5	14	2,8	228,7
Hepatit	ABCMiner	2	3	60.395	%89,93	%93,75	-3,8%	3	9	3	212,7
Hepatit	ABCMiner	2	4	60.502	%90,65	%81,25	%9,4	3	11	3,7	209,6
Hepatit	ABCMiner	2	5	80.583	%93,57	%80,00	%13,6	5	14	2,8	224,5
Hepatit	ABCMiner	2	6	80.593	%94,29	%80,00	%14,3	5	15	3	226,3
Hepatit	ABCMiner	2	7	60.376	%92,86	%66,67	%26,2	3	7	2,3	207
Hepatit	ABCMiner	2	8	80.641	%93,57	%80,00	%13,6	5	16	3,2	233,6
Hepatit	ABCMiner	2	9	80.575	%94,29	%86,67	%7,6	5	15	3	224,8
Hepatit	ABCMiner	3	0	80.528	%91,37	%81,25	%10,1	5	12	2,4	220
Hepatit	ABCMiner	3	1	47.523	%92,81	%68,75	%24,1	4	11	2,8	180,5
Hepatit	ABCMiner	3	2	80.553	%91,37	%81,25	%10,1	5	12	2,4	208
Hepatit	ABCMiner	3	3	80.576	%92,09	%93,75	-1,7%	5	16	3,2	218,3
Hepatit	ABCMiner	3	4	80.603	%92,09	%68,75	%23,3	5	13	2,6	219,7
Hepatit	ABCMiner	3	5	60.391	%92,14	%60,00	%32,1	4	13	3,3	203,3
Hepatit	ABCMiner	3	6	80.642	%93,57	%86,67	%6,9	5	16	3,2	229,1
Hepatit	ABCMiner	3	7	80.612	%93,57	%73,33	%20,2	5	13	2,6	217
Hepatit	ABCMiner	3	8	80.582	%92,14	%80,00	%12,1	5	15	3	223,9
Hepatit	ABCMiner	3	9	74.969	%95,71	%73,33	%22,4	5	12	2,4	236,5
Hepatit	ABCMiner	4	0	60.394	%89,21	%81,25	%8	4	12	3	143,7
Hepatit	ABCMiner	4	1	60.377	%91,37	%62,50	%28,9	4	11	2,8	147,6
Hepatit	ABCMiner	4	2	60.412	%92,09	%68,75	%23,3	4	10	2,5	148,3
Hepatit	ABCMiner	4	3	80.620	%92,09	%62,50	%29,6	5	15	3	164,7
Hepatit	ABCMiner	4	4	80.561	%92,81	%81,25	%11,6	5	12	2,4	161,9
Hepatit	ABCMiner	4	5	80.573	%92,86	%100	-7,1%	5	16	3,2	173
Hepatit	ABCMiner	4	6	60.401	%90,00	%66,67	%23,3	4	12	3	152,6
Hepatit	ABCMiner	4	7	60.425	%92,86	%73,33	%19,5	3	10	3,3	153,4
Hepatit	ABCMiner	4	8	60.379	%89,29	%73,33	%16	3	7	2,3	151,7
Hepatit	ABCMiner	4	9	60.398	%91,43	%80,00	%11,4	3	8	2,7	155,2
Hepatit	ABCMiner	5	0	60.365	%88,49	%81,25	%7,2	3	6	2	161,2
Hepatit	ABCMiner	5	1	80.590	%92,09	%56,25	%35,8	5	15	3	171,6
Hepatit	ABCMiner	5	2	60.420	%92,09	%62,50	%29,6	4	8	2	144,4
Hepatit	ABCMiner	5	3	60.384	%89,93	%75,00	%14,9	4	13	3,3	158,6
Hepatit	ABCMiner	5	4	80.575	%92,81	%81,25	%11,6	5	13	2,6	171,8
Hepatit	ABCMiner	5	5	60.439	%90,71	%86,67	%4	4	12	3	164
Hepatit	ABCMiner	5	6	60.405	%90,71	%73,33	%17,4	4	11	2,8	159,3
Hepatit	ABCMiner	5	7	60.433	%91,43	%66,67	%24,8	4	12	3	151,7

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hepatit	ABCMiner	5	8	80.571	%93,57	%80,00	%13,6	5	15	3	172,7
Hepatit	ABCMiner	5	9	60.386	%92,14	%66,67	%25,5	4	10	2,5	154,9
Hepatit	C4.5	-	1	-	%89,21	%87,50	%1,7	5	8	1,6	0,5
Hepatit	C4.5	-	2	-	%91,37	%81,25	%10,1	8	15	1,9	0,5
Hepatit	C4.5	-	3	-	%88,49	%93,75	-5,3%	7	11	1,6	0,5
Hepatit	C4.5	-	4	-	%92,09	%87,50	%4,6	6	11	1,8	0,5
Hepatit	C4.5	-	5	-	%92,81	%62,50	%30,3	8	14	1,8	0,5
Hepatit	C4.5	-	6	-	%86,43	%86,67	-0,2%	7	12	1,7	0,5
Hepatit	C4.5	-	7	-	%89,29	%86,67	%2,6	6	11	1,8	0,5
Hepatit	C4.5	-	8	-	%90,00	%73,33	%16,7	6	10	1,7	0,5
Hepatit	C4.5	-	9	-	%84,29	%100	-15,7%	7	12	1,7	0,5
Hepatit	C4.5	-	10	-	%90,71	%80,00	%10,7	6	7	1,2	0,5
Hepatit	CoABCMiner	1	0	110.529	%92,09	%87,50	%4,6	15	70	4,7	1,4
Hepatit	CoABCMiner	1	1	110.528	%92,81	%87,50	%5,3	14	66	4,7	1,4
Hepatit	CoABCMiner	1	2	110.543	%92,81	%81,25	%11,6	12	52	4,3	1,3
Hepatit	CoABCMiner	1	3	110.542	%93,53	%81,25	%12,3	17	87	5,1	1,4
Hepatit	CoABCMiner	1	4	110.534	%94,24	%75,00	%19,2	14	80	5,7	1,4
Hepatit	CoABCMiner	1	5	110.517	%92,14	%93,33	-1,2%	12	65	5,4	1,5
Hepatit	CoABCMiner	1	6	110.526	%92,14	%86,67	%5,5	15	78	5,2	1,5
Hepatit	CoABCMiner	1	7	110.546	%93,57	%66,67	%26,9	10	52	5,2	1,4
Hepatit	CoABCMiner	1	8	110.506	%92,14	%93,33	-1,2%	13	66	5,1	1,5
Hepatit	CoABCMiner	1	9	110.538	%93,57	%73,33	%20,2	15	71	4,7	1,4
Hepatit	CoABCMiner	2	0	110.546	%91,37	%100	-8,6%	11	64	5,8	1,4
Hepatit	CoABCMiner	2	1	110.517	%93,53	%87,50	%6	14	78	5,6	1,4
Hepatit	CoABCMiner	2	2	110.544	%92,09	%75,00	%17,1	14	61	4,4	1,5
Hepatit	CoABCMiner	2	3	110.537	%94,24	%75,00	%19,2	18	102	5,7	1,4
Hepatit	CoABCMiner	2	4	110.548	%93,53	%75,00	%18,5	15	69	4,6	1,5
Hepatit	CoABCMiner	2	5	110.544	%92,86	%100	-7,1%	15	79	5,3	1,5
Hepatit	CoABCMiner	2	6	110.550	%92,86	%80,00	%12,9	13	69	5,3	1,4
Hepatit	CoABCMiner	2	7	110.552	%92,86	%60,00	%32,9	12	56	4,7	1,4
Hepatit	CoABCMiner	2	8	110.531	%91,43	%100	-8,6%	14	70	5	1,5
Hepatit	CoABCMiner	2	9	110.519	%94,29	%73,33	%21	12	56	4,7	1,4
Hepatit	CoABCMiner	3	0	110.520	%92,09	%93,75	-1,7%	13	65	5	1,4
Hepatit	CoABCMiner	3	1	110.529	%94,24	%87,50	%6,7	13	59	4,5	1,3
Hepatit	CoABCMiner	3	2	110.540	%93,53	%81,25	%12,3	13	58	4,5	1,4
Hepatit	CoABCMiner	3	3	110.525	%93,53	%93,75	-0,2%	16	84	5,3	1,3
Hepatit	CoABCMiner	3	4	110.536	%93,53	%81,25	%12,3	10	52	5,2	1,4
Hepatit	CoABCMiner	3	5	110.529	%92,14	%93,33	-1,2%	16	76	4,8	1,5
Hepatit	CoABCMiner	3	6	110.534	%92,14	%86,67	%5,5	12	67	5,6	1,4
Hepatit	CoABCMiner	3	7	110.551	%92,86	%60,00	%32,9	13	56	4,3	1,5
Hepatit	CoABCMiner	3	8	110.527	%92,86	%100	-7,1%	12	56	4,7	1,4
Hepatit	CoABCMiner	3	9	110.523	%95,71	%73,33	%22,4	16	75	4,7	1,4
Hepatit	CoABCMiner	4	0	110.527	%92,81	%87,50	%5,3	17	81	4,8	1,3
Hepatit	CoABCMiner	4	1	110.531	%93,53	%87,50	%6	12	64	5,3	1,5
Hepatit	CoABCMiner	4	2	110.555	%92,09	%81,25	%10,8	17	84	4,9	1,4
Hepatit	CoABCMiner	4	3	110.547	%93,53	%81,25	%12,3	18	86	4,8	1,5
Hepatit	CoABCMiner	4	4	110.531	%94,24	%68,75	%25,5	15	76	5,1	1,5
Hepatit	CoABCMiner	4	5	110.532	%92,86	%100	-7,1%	16	78	4,9	1,6
Hepatit	CoABCMiner	4	6	110.538	%93,57	%73,33	%20,2	15	73	4,9	1,5
Hepatit	CoABCMiner	4	7	110.548	%93,57	%66,67	%26,9	11	37	3,4	1,4
Hepatit	CoABCMiner	4	8	110.516	%92,86	%86,67	%6,2	14	84	6	1,4
Hepatit	CoABCMiner	4	9	110.532	%94,29	%73,33	%21	16	68	4,3	1,4
Hepatit	CoABCMiner	5	0	110.511	%92,81	%81,25	%11,6	16	81	5,1	1,4
Hepatit	CoABCMiner	5	1	110.525	%92,81	%81,25	%11,6	18	94	5,2	1,4
Hepatit	CoABCMiner	5	2	110.542	%92,09	%75,00	%17,1	14	62	4,4	1,5
Hepatit	CoABCMiner	5	3	110.527	%93,53	%87,50	%6	13	74	5,7	1,4
Hepatit	CoABCMiner	5	4	110.535	%93,53	%62,50	%31	15	64	4,3	1,4
Hepatit	CoABCMiner	5	5	110.549	%92,86	%93,33	-0,5%	17	97	5,7	1,4
Hepatit	CoABCMiner	5	6	110.545	%92,86	%86,67	%6,2	13	57	4,4	1,4
Hepatit	CoABCMiner	5	7	110.562	%93,57	%60,00	%33,6	13	54	4,2	1,4
Hepatit	CoABCMiner	5	8	110.511	%92,86	%93,33	-0,5%	17	89	5,2	1,4
Hepatit	CoABCMiner	5	9	110.538	%93,57	%73,33	%20,2	11	54	4,9	1,4
Hepatit	CORE	1	0	1.965.581	%89,93	%93,75	-3,8%	8	35	4,4	30,1
Hepatit	CORE	1	1	1.966.353	%92,09	%75,00	%17,1	7	35	5	31,5
Hepatit	CORE	1	2	1.964.793	%89,93	%81,25	%8,7	7	34	4,9	31,1
Hepatit	CORE	1	3	1.966.007	%92,09	%87,50	%4,6	5	19	3,8	32,9

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hepatit	CORE	1	4	1.964.903	%92,81	%75,00	%17,8	8	42	5,3	29,2
Hepatit	CORE	1	5	1.964.290	%90,71	%80,00	%10,7	7	24	3,4	31,3
Hepatit	CORE	1	6	1.965.485	%90,71	%93,33	-2,6%	6	22	3,7	32,1
Hepatit	CORE	1	7	1.966.257	%91,43	%60,00	%31,4	6	27	4,5	30,8
Hepatit	CORE	1	8	1.967.214	%89,29	%86,67	%2,6	5	21	4,2	30
Hepatit	CORE	1	9	1.963.359	%90,71	%73,33	%17,4	3	16	5,3	32,6
Hepatit	CORE	2	0	-	%91,37	%81,25	%10,1	11	47	4,3	29,4
Hepatit	CORE	2	1	-	%91,37	%87,50	%3,9	7	39	5,6	30,6
Hepatit	CORE	2	2	-	%92,81	%87,50	%5,3	4	15	3,8	28,5
Hepatit	CORE	2	3	-	%90,65	%87,50	%3,1	6	29	4,8	28,3
Hepatit	CORE	2	4	-	%92,09	%75,00	%17,1	14	65	4,6	32,3
Hepatit	CORE	2	5	-	%90,71	%93,33	-2,6%	12	58	4,8	30,6
Hepatit	CORE	2	6	-	%91,43	%86,67	%4,8	11	58	5,3	30,2
Hepatit	CORE	2	7	-	%92,14	%73,33	%18,8	6	32	5,3	33,9
Hepatit	CORE	2	8	-	%90,00	%80,00	%10	6	31	5,2	30,5
Hepatit	CORE	2	9	-	%91,43	%73,33	%18,1	7	45	6,4	32,4
Hepatit	CORE	3	0	-	%92,09	%87,50	%4,6	9	48	5,3	29
Hepatit	CORE	3	1	-	%91,37	%81,25	%10,1	6	28	4,7	27,7
Hepatit	CORE	3	2	-	%91,37	%75,00	%16,4	5	26	5,2	27,5
Hepatit	CORE	3	3	-	%89,93	%81,25	%8,7	10	37	3,7	30,2
Hepatit	CORE	3	4	-	%92,09	%75,00	%17,1	7	41	5,9	30,7
Hepatit	CORE	3	5	-	%90,71	%93,33	-2,6%	6	32	5,3	31,8
Hepatit	CORE	3	6	-	%90,71	%93,33	-2,6%	9	47	5,2	30,7
Hepatit	CORE	3	7	-	%90,71	%60,00	%30,7	13	64	4,9	30,9
Hepatit	CORE	3	8	-	%90,71	%86,67	%4	6	29	4,8	29,2
Hepatit	CORE	3	9	-	%92,14	%73,33	%18,8	9	56	6,2	32,9
Hepatit	CORE	4	0	-	%90,65	%93,75	-3,1%	11	49	4,5	28,3
Hepatit	CORE	4	1	-	%91,37	%75,00	%16,4	6	30	5	31,6
Hepatit	CORE	4	2	-	%92,09	%68,75	%23,3	6	36	6	32,4
Hepatit	CORE	4	3	-	%91,37	%87,50	%3,9	5	30	6	31,1
Hepatit	CORE	4	4	-	%92,81	%75,00	%17,8	10	59	5,9	31,7
Hepatit	CORE	4	5	-	%90,00	%80,00	%10	4	19	4,8	29,5
Hepatit	CORE	4	6	-	%90,71	%93,33	-2,6%	4	16	4	29,2
Hepatit	CORE	4	7	-	%93,57	%66,67	%26,9	8	37	4,6	32,7
Hepatit	CORE	4	8	-	%90,71	%80,00	%10,7	6	33	5,5	29
Hepatit	CORE	4	9	-	%91,43	%73,33	%18,1	6	32	5,3	32,6
Hepatit	CORE	5	0	-	%89,93	%87,50	%2,4	10	43	4,3	30,8
Hepatit	CORE	5	1	-	%91,37	%68,75	%22,6	10	46	4,6	31,4
Hepatit	CORE	5	2	-	%92,09	%81,25	%10,8	11	66	6	30,2
Hepatit	CORE	5	3	-	%89,93	%87,50	%2,4	13	57	4,4	28,8
Hepatit	CORE	5	4	-	%91,37	%75,00	%16,4	5	23	4,6	31,2
Hepatit	CORE	5	5	-	%92,14	%93,33	-1,2%	8	41	5,1	29,7
Hepatit	CORE	5	6	-	%90,00	%100	-10,0%	10	54	5,4	29,5
Hepatit	CORE	5	7	-	%92,86	%66,67	%26,2	12	72	6	34,2
Hepatit	CORE	5	8	-	%90,71	%86,67	%4	12	59	4,9	28
Hepatit	CORE	5	9	-	%90,00	%80,00	%10	8	39	4,9	30
Hepatit	HIDER	1	0	-	%93,10	%75,00	%18,1	3	19	6,3	3
Hepatit	HIDER	1	1	-	%93,10	%87,50	%5,6	3	21	7	2
Hepatit	HIDER	1	2	-	%95,80	%75,00	%20,8	5	29	5,8	4
Hepatit	HIDER	1	3	-	%90,30	%75,00	%15,3	3	18	6	3
Hepatit	HIDER	1	4	-	%94,10	%75,00	%19,1	4	23	5,8	3
Hepatit	HIDER	1	5	-	%97,30	%83,30	%14	6	35	5,8	4
Hepatit	HIDER	1	6	-	%93,20	%85,70	%7,5	4	23	5,8	3
Hepatit	HIDER	1	7	-	%95,90	%66,70	%29,2	5	31	6,2	4
Hepatit	HIDER	1	8	-	%94,50	%100	-5,5%	4	24	6	3
Hepatit	HIDER	1	9	-	%91,40	%80,00	%11,4	4	25	6,3	3
Hepatit	HIDER	2	0	-	%95,80	%75,00	%20,8	3	20	6,7	3
Hepatit	HIDER	2	1	-	%94,40	%87,50	%6,9	3	20	6,7	2
Hepatit	HIDER	2	2	-	%94,40	%75,00	%19,4	4	25	6,3	4
Hepatit	HIDER	2	3	-	%90,30	%100	-9,7%	3	18	6	3
Hepatit	HIDER	2	4	-	%95,60	%75,00	%20,6	5	29	5,8	3
Hepatit	HIDER	2	5	-	%95,90	%83,30	%12,6	7	41	5,9	4
Hepatit	HIDER	2	6	-	%91,80	%85,70	%6,1	4	24	6	3
Hepatit	HIDER	2	7	-	%98,60	%66,70	%31,9	6	38	6,3	4
Hepatit	HIDER	2	8	-	%94,50	%85,70	%8,8	6	35	5,8	3
Hepatit	HIDER	2	9	-	%95,70	%90,00	%5,7	5	32	6,4	3

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hepatit	HIDER	3	0	-	%93,10	%87,50	%5,6	4	25	6,3	3
Hepatit	HIDER	3	1	-	%97,20	%87,50	%9,7	5	30	6	2
Hepatit	HIDER	3	2	-	%94,40	%87,50	%6,9	4	25	6,3	4
Hepatit	HIDER	3	3	-	%90,30	%75,00	%15,3	4	23	5,8	3
Hepatit	HIDER	3	4	-	%91,20	%83,30	%7,9	3	18	6	3
Hepatit	HIDER	3	5	-	%89,20	%66,70	%22,5	2	13	6,5	4
Hepatit	HIDER	3	6	-	%93,20	%85,70	%7,5	4	24	6	3
Hepatit	HIDER	3	7	-	%91,90	%66,70	%25,2	4	24	6	4
Hepatit	HIDER	3	8	-	%95,90	%100	-4,1%	5	31	6,2	3
Hepatit	HIDER	3	9	-	%94,30	%90,00	%4,3	5	30	6	3
Hepatit	HIDER	4	0	-	%91,70	%75,00	%16,7	3	19	6,3	3
Hepatit	HIDER	4	1	-	%97,20	%87,50	%9,7	5	32	6,4	2
Hepatit	HIDER	4	2	-	%93,10	%75,00	%18,1	4	25	6,3	4
Hepatit	HIDER	4	3	-	%94,40	%87,50	%6,9	4	22	5,5	3
Hepatit	HIDER	4	4	-	%92,60	%66,70	%25,9	4	23	5,8	3
Hepatit	HIDER	4	5	-	%95,90	%83,30	%12,6	5	30	6	4
Hepatit	HIDER	4	6	-	%93,20	%100	-6,8%	4	24	6	3
Hepatit	HIDER	4	7	-	%93,20	%66,70	%26,5	4	25	6,3	4
Hepatit	HIDER	4	8	-	%94,50	%100	-5,5%	5	30	6	3
Hepatit	HIDER	4	9	-	%94,30	%80,00	%14,3	5	30	6	3
Hepatit	HIDER	5	0	-	%91,70	%87,50	%4,2	3	18	6	3
Hepatit	HIDER	5	1	-	%95,80	%75,00	%20,8	4	26	6,5	2
Hepatit	HIDER	5	2	-	%97,20	%75,00	%22,2	5	31	6,2	4
Hepatit	HIDER	5	3	-	%93,10	%75,00	%18,1	4	23	5,8	3
Hepatit	HIDER	5	4	-	%94,10	%66,70	%27,4	3	19	6,3	3
Hepatit	HIDER	5	5	-	%95,90	%83,30	%12,6	3	20	6,7	4
Hepatit	HIDER	5	6	-	%95,90	%100	-4,1%	5	31	6,2	3
Hepatit	HIDER	5	7	-	%95,90	%66,70	%29,2	4	25	6,3	4
Hepatit	HIDER	5	8	-	%95,90	%100	-4,1%	6	35	5,8	3
Hepatit	HIDER	5	9	-	%95,70	%80,00	%15,7	5	32	6,4	3
Hepatit	LDWPSO	1	0	60.045	%89,21	%87,50	%1,7	4	9	2,3	262,8
Hepatit	LDWPSO	1	1	60.049	%89,93	%68,75	%21,2	3	6	2	304,3
Hepatit	LDWPSO	1	2	80.082	%93,53	%68,75	%24,8	5	13	2,6	294,2
Hepatit	LDWPSO	1	3	80.064	%91,37	%68,75	%22,6	5	10	2	289,3
Hepatit	LDWPSO	1	4	80.058	%89,21	%81,25	%8	5	9	1,8	306,6
Hepatit	LDWPSO	1	5	80.080	%89,29	%73,33	%16	5	13	2,6	312,8
Hepatit	LDWPSO	1	6	80.054	%90,00	%80,00	%10	5	10	2	800
Hepatit	LDWPSO	1	7	80.059	%93,57	%53,33	%40,2	5	11	2,2	302,5
Hepatit	LDWPSO	1	8	60.100	%90,00	%86,67	%3,3	4	11	2,8	308,7
Hepatit	LDWPSO	1	9	80.085	%94,29	%80,00	%14,3	5	11	2,2	449,3
Hepatit	LDWPSO	2	0	60.038	%89,93	%75,00	%14,9	4	7	1,8	257,9
Hepatit	LDWPSO	2	1	60.042	%89,93	%68,75	%21,2	3	6	2	263,5
Hepatit	LDWPSO	2	2	80.077	%92,81	%81,25	%11,6	5	12	2,4	282,7
Hepatit	LDWPSO	2	3	60.057	%89,21	%93,75	-4,5%	3	8	2,7	248,8
Hepatit	LDWPSO	2	4	80.133	%93,53	%75,00	%18,5	4	10	2,5	299,3
Hepatit	LDWPSO	2	5	80.072	%92,14	%80,00	%12,1	5	14	2,8	285,5
Hepatit	LDWPSO	2	6	60.156	%87,86	%80,00	%7,9	3	9	3	272,1
Hepatit	LDWPSO	2	7	80.047	%91,43	%80,00	%11,4	5	8	1,6	356,6
Hepatit	LDWPSO	2	8	60.172	%90,71	%86,67	%4	3	10	3,3	324,2
Hepatit	LDWPSO	2	9	80.164	%89,29	%73,33	%16	5	11	2,2	294,4
Hepatit	LDWPSO	3	0	80.071	%92,09	%81,25	%10,8	4	8	2	333
Hepatit	LDWPSO	3	1	80.047	%92,81	%81,25	%11,6	5	11	2,2	298,8
Hepatit	LDWPSO	3	2	80.062	%91,37	%93,75	-2,4%	5	12	2,4	285,4
Hepatit	LDWPSO	3	3	100.088	%94,96	%75,00	%20	6	15	2,5	281,6
Hepatit	LDWPSO	3	4	60.040	%87,77	%75,00	%12,8	4	7	1,8	223,2
Hepatit	LDWPSO	3	5	80.068	%90,00	%73,33	%16,7	5	12	2,4	346,3
Hepatit	LDWPSO	3	6	80.061	%94,29	%66,67	%27,6	5	11	2,2	300,5
Hepatit	LDWPSO	3	7	100.070	%93,57	%66,67	%26,9	6	12	2	995,9
Hepatit	LDWPSO	3	8	80.078	%92,86	%86,67	%6,2	5	12	2,4	419,7
Hepatit	LDWPSO	3	9	60.053	%90,00	%80,00	%10	4	12	3	971,9
Hepatit	LDWPSO	4	0	80.046	%89,93	%81,25	%8,7	5	9	1,8	287,5
Hepatit	LDWPSO	4	1	60.043	%89,93	%81,25	%8,7	4	7	1,8	268,7
Hepatit	LDWPSO	4	2	60.038	%92,09	%75,00	%17,1	4	8	2	284,3
Hepatit	LDWPSO	4	3	60.086	%91,37	%62,50	%28,9	4	9	2,3	257,3
Hepatit	LDWPSO	4	4	100.109	%94,96	%81,25	%13,7	6	14	2,3	393,4
Hepatit	LDWPSO	4	5	60.097	%90,71	%73,33	%17,4	4	10	2,5	278,3

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hepatit	LDWPSO	4	6	60.034	%89,29	%80,00	%9,3	4	7	1,8	330,2
Hepatit	LDWPSO	4	7	100.065	%92,86	%80,00	%12,9	6	11	1,8	389,3
Hepatit	LDWPSO	4	8	80.044	%89,29	%86,67	%2,6	5	9	1,8	403,4
Hepatit	LDWPSO	4	9	60.044	%90,00	%80,00	%10	4	7	1,8	311,9
Hepatit	LDWPSO	5	0	100.081	%90,65	%87,50	%3,1	6	13	2,2	323,4
Hepatit	LDWPSO	5	1	80.059	%89,93	%62,50	%27,4	5	9	1,8	268,3
Hepatit	LDWPSO	5	2	80.064	%91,37	%75,00	%16,4	5	11	2,2	319,1
Hepatit	LDWPSO	5	3	80.084	%91,37	%75,00	%16,4	5	13	2,6	280,8
Hepatit	LDWPSO	5	4	80.069	%87,77	%87,50	%0,3	5	12	2,4	313,2
Hepatit	LDWPSO	5	5	60.033	%90,71	%86,67	%4	4	7	1,8	270,1
Hepatit	LDWPSO	5	6	80.064	%92,86	%73,33	%19,5	5	10	2	299,7
Hepatit	LDWPSO	5	7	80.066	%93,57	%66,67	%26,9	5	12	2,4	307,4
Hepatit	LDWPSO	5	8	80.052	%88,57	%46,67	%41,9	5	9	1,8	319,3
Hepatit	LDWPSO	5	9	100.089	%92,86	%73,33	%19,5	6	15	2,5	327,2
Hepatit	PGIRLA	1	0	-	%98,61	%100	-1,4%	20	179	9	1
Hepatit	PGIRLA	1	1	-	%98,61	%75,00	%23,6	20	185	9,3	1
Hepatit	PGIRLA	1	2	-	%97,22	%75,00	%22,2	20	214	10,7	1
Hepatit	PGIRLA	1	3	-	%97,22	%87,50	%9,7	20	185	9,3	1
Hepatit	PGIRLA	1	4	-	%98,53	%91,67	%6,9	20	206	10,3	0,6
Hepatit	PGIRLA	1	5	-	%95,95	%100	-4,1%	20	191	9,6	1
Hepatit	PGIRLA	1	6	-	%98,63	%100	-1,4%	20	185	9,3	1
Hepatit	PGIRLA	1	7	-	%98,65	%83,33	%15,3	20	199	10	1
Hepatit	PGIRLA	1	8	-	%98,63	%100	-1,4%	20	207	10,4	1
Hepatit	PGIRLA	1	9	-	%97,14	%90,00	%7,1	20	207	10,4	1
Hepatit	PGIRLA	2	0	-	%95,83	%100	-4,2%	20	221	11,1	1
Hepatit	PGIRLA	2	1	-	%98,61	%87,50	%11,1	20	215	10,8	1
Hepatit	PGIRLA	2	2	-	%98,61	%87,50	%11,1	20	196	9,8	1
Hepatit	PGIRLA	2	3	-	%98,61	%100	-1,4%	20	195	9,8	1
Hepatit	PGIRLA	2	4	-	%98,53	%83,33	%15,2	20	210	10,5	0,6
Hepatit	PGIRLA	2	5	-	%98,65	%100	-1,4%	20	191	9,6	1
Hepatit	PGIRLA	2	6	-	%95,89	%100	-4,1%	20	183	9,2	1
Hepatit	PGIRLA	2	7	-	%100	%83,33	%16,7	20	204	10,2	1
Hepatit	PGIRLA	2	8	-	%98,63	%100	-1,4%	20	186	9,3	1
Hepatit	PGIRLA	2	9	-	%95,71	%90,00	%5,7	20	202	10,1	1
Hepatit	PGIRLA	3	0	-	%98,61	%87,50	%11,1	20	190	9,5	1
Hepatit	PGIRLA	3	1	-	%98,61	%87,50	%11,1	20	197	9,9	1
Hepatit	PGIRLA	3	2	-	%97,22	%75,00	%22,2	20	199	10	1
Hepatit	PGIRLA	3	3	-	%98,61	%100	-1,4%	20	200	10	1
Hepatit	PGIRLA	3	4	-	%98,53	%83,33	%15,2	20	199	10	0,6
Hepatit	PGIRLA	3	5	-	%97,30	%83,33	%14	20	205	10,3	1
Hepatit	PGIRLA	3	6	-	%98,63	%100	-1,4%	20	193	9,7	1
Hepatit	PGIRLA	3	7	-	%98,65	%83,33	%15,3	20	199	10	1
Hepatit	PGIRLA	3	8	-	%98,63	%100	-1,4%	20	202	10,1	1
Hepatit	PGIRLA	3	9	-	%97,14	%90,00	%7,1	20	206	10,3	1
Hepatit	PGIRLA	4	0	-	%97,22	%100	-2,8%	20	194	9,7	1
Hepatit	PGIRLA	4	1	-	%98,61	%75,00	%23,6	20	193	9,7	1
Hepatit	PGIRLA	4	2	-	%95,83	%87,50	%8,3	20	192	9,6	1
Hepatit	PGIRLA	4	3	-	%98,61	%100	-1,4%	20	199	10	1
Hepatit	PGIRLA	4	4	-	%98,53	%83,33	%15,2	20	191	9,6	0,6
Hepatit	PGIRLA	4	5	-	%98,65	%50,00	%48,6	20	211	10,6	1
Hepatit	PGIRLA	4	6	-	%100	%100	%0	20	188	9,4	1
Hepatit	PGIRLA	4	7	-	%98,65	%83,33	%15,3	20	192	9,6	1
Hepatit	PGIRLA	4	8	-	%98,63	%100	-1,4%	20	183	9,2	1
Hepatit	PGIRLA	4	9	-	%97,14	%100	-2,9%	20	212	10,6	1
Hepatit	PGIRLA	5	0	-	%98,61	%87,50	%11,1	20	197	9,9	1
Hepatit	PGIRLA	5	1	-	%95,83	%100	-4,2%	20	198	9,9	1
Hepatit	PGIRLA	5	2	-	%98,61	%87,50	%11,1	20	185	9,3	1
Hepatit	PGIRLA	5	3	-	%98,61	%100	-1,4%	20	198	9,9	1
Hepatit	PGIRLA	5	4	-	%98,53	%83,33	%15,2	20	188	9,4	0,6
Hepatit	PGIRLA	5	5	-	%98,65	%83,33	%15,3	20	193	9,7	1
Hepatit	PGIRLA	5	6	-	%97,26	%100	-2,7%	20	200	10	1
Hepatit	PGIRLA	5	7	-	%100	%83,33	%16,7	20	194	9,7	1
Hepatit	PGIRLA	5	8	-	%98,63	%100	-1,4%	20	193	9,7	1
Hepatit	PGIRLA	5	9	-	%97,14	%90,00	%7,1	20	203	10,2	1
Hepatit	SIA	1	0	-	%99,28	%62,50	%36,8	65	622	9,6	2
Hepatit	SIA	1	1	-	%98,56	%81,25	%17,3	91	812	8,9	2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Hepatit	SIA	1	2	-	%99,28	%75,00	%24,3	61	620	10,2	2
Hepatit	SIA	1	3	-	%99,28	%81,25	%18	70	647	9,2	2
Hepatit	SIA	1	4	-	%97,84	%75,00	%22,8	69	788	11,4	2
Hepatit	SIA	1	5	-	%97,14	%86,67	%10,5	79	945	12	2
Hepatit	SIA	1	6	-	%97,86	%73,33	%24,5	58	673	11,6	2
Hepatit	SIA	1	7	-	%99,29	%73,33	%26	64	814	12,7	2
Hepatit	SIA	1	8	-	%100	%86,67	%13,3	82	818	10	3
Hepatit	SIA	1	9	-	%99,29	%80,00	%19,3	61	610	10	2
Hepatit	SIA	2	0	-	%99,28	%62,50	%36,8	77	606	7,9	2
Hepatit	SIA	2	1	-	%99,28	%75,00	%24,3	68	605	8,9	2
Hepatit	SIA	2	2	-	%98,56	%75,00	%23,6	63	696	11	2
Hepatit	SIA	2	3	-	%99,28	%75,00	%24,3	70	851	12,2	2
Hepatit	SIA	2	4	-	%96,40	%81,25	%15,2	82	543	6,6	2
Hepatit	SIA	2	5	-	%99,29	%86,67	%12,6	69	647	9,4	2
Hepatit	SIA	2	6	-	%98,57	%80,00	%18,6	84	663	7,9	2
Hepatit	SIA	2	7	-	%98,57	%80,00	%18,6	56	581	10,4	2
Hepatit	SIA	2	8	-	%99,29	%80,00	%19,3	69	645	9,3	2
Hepatit	SIA	2	9	-	%100	%80,00	%20	75	655	8,7	2
Hepatit	SIA	3	0	-	%98,56	%62,50	%36,1	65	673	10,4	2
Hepatit	SIA	3	1	-	%97,84	%87,50	%10,3	81	861	10,6	2
Hepatit	SIA	3	2	-	%98,56	%81,25	%17,3	72	705	9,8	2
Hepatit	SIA	3	3	-	%97,84	%81,25	%16,6	62	588	9,5	2
Hepatit	SIA	3	4	-	%99,28	%75,00	%24,3	70	728	10,4	2
Hepatit	SIA	3	5	-	%99,29	%93,33	%6	75	814	10,9	2
Hepatit	SIA	3	6	-	%97,86	%93,33	%4,5	58	701	12,1	2
Hepatit	SIA	3	7	-	%99,29	%73,33	%26	63	795	12,6	2
Hepatit	SIA	3	8	-	%100	%80,00	%20	73	746	10,2	2
Hepatit	SIA	3	9	-	%100	%80,00	%20	67	774	11,6	2
Hepatit	SIA	4	0	-	%98,56	%68,75	%29,8	68	553	8,1	2
Hepatit	SIA	4	1	-	%97,84	%75,00	%22,8	83	852	10,3	2
Hepatit	SIA	4	2	-	%97,12	%81,25	%15,9	85	569	6,7	3
Hepatit	SIA	4	3	-	%97,84	%75,00	%22,8	71	706	9,9	2
Hepatit	SIA	4	4	-	%94,24	%81,25	%13	62	781	12,6	2
Hepatit	SIA	4	5	-	%99,29	%100	-0,7%	73	594	8,1	2
Hepatit	SIA	4	6	-	%99,29	%86,67	%12,6	72	533	7,4	2
Hepatit	SIA	4	7	-	%99,29	%73,33	%26	64	570	8,9	2
Hepatit	SIA	4	8	-	%100	%80,00	%20	73	630	8,6	2
Hepatit	SIA	4	9	-	%100	%80,00	%20	69	632	9,2	2
Hepatit	SIA	5	0	-	%99,28	%62,50	%36,8	77	792	10,3	3
Hepatit	SIA	5	1	-	%99,28	%68,75	%30,5	65	713	11	3
Hepatit	SIA	5	2	-	%99,28	%62,50	%36,8	61	685	11,2	2
Hepatit	SIA	5	3	-	%99,28	%93,75	%5,5	70	661	9,4	3
Hepatit	SIA	5	4	-	%97,84	%75,00	%22,8	73	642	8,8	3
Hepatit	SIA	5	5	-	%99,29	%93,33	%6	78	627	8	3
Hepatit	SIA	5	6	-	%97,86	%80,00	%17,9	78	731	9,4	3
Hepatit	SIA	5	7	-	%98,57	%66,67	%31,9	68	677	10	3
Hepatit	SIA	5	8	-	%100	%86,67	%13,3	67	702	10,5	3
Hepatit	SIA	5	9	-	%100	%80,00	%20	65	624	9,6	2
Lenf Grafisi	ABCMiner	1	0	80.567	%87,97	%60,00	%28	5	7	1,4	244,4
Lenf Grafisi	ABCMiner	1	1	80.561	%84,21	%80,00	%4,2	5	10	2	239
Lenf Grafisi	ABCMiner	1	2	80.579	%85,71	%66,67	%19	5	8	1,6	238,3
Lenf Grafisi	ABCMiner	1	3	100.705	%85,71	%40,00	%45,7	6	9	1,5	272,1
Lenf Grafisi	ABCMiner	1	4	100.760	%81,20	%86,67	-5,5%	6	10	1,7	269,3
Lenf Grafisi	ABCMiner	1	5	80.565	%84,21	%60,00	%24,2	5	8	1,6	241,4
Lenf Grafisi	ABCMiner	1	6	80.565	%82,71	%80,00	%2,7	5	10	2	250,3
Lenf Grafisi	ABCMiner	1	7	80.583	%84,96	%80,00	%5	5	8	1,6	235
Lenf Grafisi	ABCMiner	1	8	80.576	%84,33	%35,71	%48,6	5	10	2	249,3
Lenf Grafisi	ABCMiner	1	9	80.576	%85,07	%35,71	%49,4	5	10	2	246,1
Lenf Grafisi	ABCMiner	2	0	80.572	%84,21	%73,33	%10,9	5	11	2,2	260
Lenf Grafisi	ABCMiner	2	1	80.572	%80,45	%86,67	-6,2%	4	6	1,5	238,2
Lenf Grafisi	ABCMiner	2	2	96.939	%86,47	%66,67	%19,8	6	12	2	268,4
Lenf Grafisi	ABCMiner	2	3	100.743	%86,47	%60,00	%26,5	6	10	1,7	265,2
Lenf Grafisi	ABCMiner	2	4	100.736	%81,95	%80,00	%2	6	10	1,7	269,3
Lenf Grafisi	ABCMiner	2	5	80.603	%85,71	%53,33	%32,4	5	7	1,4	239
Lenf Grafisi	ABCMiner	2	6	100.745	%84,21	%80,00	%4,2	6	11	1,8	280,4
Lenf Grafisi	ABCMiner	2	7	100.747	%86,47	%73,33	%13,1	6	11	1,8	259,8

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Lenf Grafisi	ABCMiner	2	8	80.562	%83,58	%21,43	%62,2	5	8	1,6	246,1
Lenf Grafisi	ABCMiner	2	9	80.558	%83,58	%35,71	%47,9	5	9	1,8	245,9
Lenf Grafisi	ABCMiner	3	0	80.555	%87,97	%60,00	%28	5	7	1,4	246,2
Lenf Grafisi	ABCMiner	3	1	80.557	%81,95	%86,67	-4,7%	5	7	1,4	245,8
Lenf Grafisi	ABCMiner	3	2	100.734	%87,97	%66,67	%21,3	6	12	2	263,3
Lenf Grafisi	ABCMiner	3	3	80.597	%84,96	%60,00	%25	5	8	1,6	240,4
Lenf Grafisi	ABCMiner	3	4	100.715	%78,95	%66,67	%12,3	6	13	2,2	270,9
Lenf Grafisi	ABCMiner	3	5	80.585	%84,21	%60,00	%24,2	5	9	1,8	240
Lenf Grafisi	ABCMiner	3	6	80.594	%82,71	%80,00	%2,7	5	8	1,6	244,1
Lenf Grafisi	ABCMiner	3	7	80.555	%84,21	%66,67	%17,5	5	9	1,8	254,6
Lenf Grafisi	ABCMiner	3	8	80.561	%82,84	%28,57	%54,3	5	8	1,6	252,4
Lenf Grafisi	ABCMiner	3	9	80.607	%84,33	%35,71	%48,6	5	9	1,8	244
Lenf Grafisi	ABCMiner	4	0	80.555	%87,97	%60,00	%28	5	7	1,4	195,3
Lenf Grafisi	ABCMiner	4	1	80.542	%80,45	%73,33	%7,1	5	8	1,6	197,6
Lenf Grafisi	ABCMiner	4	2	80.580	%86,47	%73,33	%13,1	5	9	1,8	175,3
Lenf Grafisi	ABCMiner	4	3	80.589	%84,21	%73,33	%10,9	5	9	1,8	178,8
Lenf Grafisi	ABCMiner	4	4	80.547	%79,70	%86,67	-7,0%	4	8	2	196,3
Lenf Grafisi	ABCMiner	4	5	80.598	%85,71	%53,33	%32,4	5	8	1,6	171,5
Lenf Grafisi	ABCMiner	4	6	80.579	%83,46	%80,00	%3,5	5	9	1,8	177,4
Lenf Grafisi	ABCMiner	4	7	80.568	%84,21	%66,67	%17,5	5	9	1,8	187,1
Lenf Grafisi	ABCMiner	4	8	100.743	%86,57	%42,86	%43,7	6	11	1,8	197,7
Lenf Grafisi	ABCMiner	4	9	100.733	%85,07	%64,29	%20,8	6	11	1,8	195,9
Lenf Grafisi	ABCMiner	5	0	80.553	%87,97	%60,00	%28	5	7	1,4	190,8
Lenf Grafisi	ABCMiner	5	1	80.570	%84,21	%93,33	-9,1%	5	9	1,8	198,2
Lenf Grafisi	ABCMiner	5	2	100.757	%87,22	%66,67	%20,6	6	12	2	200,1
Lenf Grafisi	ABCMiner	5	3	80.593	%83,46	%73,33	%10,1	5	10	2	185,7
Lenf Grafisi	ABCMiner	5	4	100.774	%82,71	%80,00	%2,7	6	12	2	198,9
Lenf Grafisi	ABCMiner	5	5	80.593	%84,21	%60,00	%24,2	5	9	1,8	185,6
Lenf Grafisi	ABCMiner	5	6	100.751	%83,46	%80,00	%3,5	6	10	1,7	209,6
Lenf Grafisi	ABCMiner	5	7	80.568	%83,46	%73,33	%10,1	5	9	1,8	192,2
Lenf Grafisi	ABCMiner	5	8	80.585	%85,82	%71,43	%14,4	5	9	1,8	189,9
Lenf Grafisi	ABCMiner	5	9	100.773	%84,33	%42,86	%41,5	6	10	1,7	199,5
Lenf Grafisi	C4.5	-	1	-	%90,98	%66,67	%24,3	11	29	2,6	0,4
Lenf Grafisi	C4.5	-	2	-	%87,97	%86,67	%1,3	8	17	2,1	0,4
Lenf Grafisi	C4.5	-	3	-	%96,24	%60,00	%36,2	12	23	1,9	0,4
Lenf Grafisi	C4.5	-	4	-	%92,48	%66,67	%25,8	11	23	2,1	0,4
Lenf Grafisi	C4.5	-	5	-	%90,98	%80,00	%11	13	26	2	0,4
Lenf Grafisi	C4.5	-	6	-	%84,21	%80,00	%4,2	10	19	1,9	0,4
Lenf Grafisi	C4.5	-	7	-	%88,72	%86,67	%2,1	14	27	1,9	0,4
Lenf Grafisi	C4.5	-	8	-	%87,97	%66,67	%21,3	10	18	1,8	0,4
Lenf Grafisi	C4.5	-	9	-	%84,33	%92,86	-8,5%	8	15	1,9	0,4
Lenf Grafisi	C4.5	-	10	-	%92,54	%92,86	-0,3%	16	34	2,1	0,4
Lenf Grafisi	CoABCMiner	1	0	110.642	%92,48	%80,00	%12,5	15	61	4,1	1,2
Lenf Grafisi	CoABCMiner	1	1	110.605	%92,48	%86,67	%5,8	15	75	5	1,4
Lenf Grafisi	CoABCMiner	1	2	110.608	%94,74	%66,67	%28,1	13	60	4,6	1,3
Lenf Grafisi	CoABCMiner	1	3	110.615	%90,98	%80,00	%11	14	64	4,6	1,3
Lenf Grafisi	CoABCMiner	1	4	110.621	%93,23	%86,67	%6,6	15	74	4,9	1,3
Lenf Grafisi	CoABCMiner	1	5	110.611	%93,23	%60,00	%33,2	12	55	4,6	1,4
Lenf Grafisi	CoABCMiner	1	6	110.611	%91,73	%86,67	%5,1	17	77	4,5	1,3
Lenf Grafisi	CoABCMiner	1	7	110.648	%91,73	%73,33	%18,4	14	66	4,7	1,3
Lenf Grafisi	CoABCMiner	1	8	110.600	%93,28	%92,86	%0,4	14	65	4,6	1,4
Lenf Grafisi	CoABCMiner	1	9	110.604	%91,79	%92,86	-1,1%	14	63	4,5	1,4
Lenf Grafisi	CoABCMiner	2	0	110.622	%91,73	%73,33	%18,4	15	62	4,1	1,2
Lenf Grafisi	CoABCMiner	2	1	110.628	%93,23	%86,67	%6,6	17	78	4,6	1,3
Lenf Grafisi	CoABCMiner	2	2	110.610	%93,99	%66,67	%27,3	14	61	4,4	1,3
Lenf Grafisi	CoABCMiner	2	3	110.622	%90,98	%86,67	%4,3	10	58	5,8	1,2
Lenf Grafisi	CoABCMiner	2	4	110.620	%93,23	%80,00	%13,2	12	60	5	1,3
Lenf Grafisi	CoABCMiner	2	5	110.600	%92,48	%73,33	%19,1	11	52	4,7	1,3
Lenf Grafisi	CoABCMiner	2	6	110.631	%92,48	%93,33	-0,9%	13	56	4,3	1,2
Lenf Grafisi	CoABCMiner	2	7	110.648	%92,48	%80,00	%12,5	15	73	4,9	1,2
Lenf Grafisi	CoABCMiner	2	8	110.613	%93,28	%92,86	%0,4	13	60	4,6	1,3
Lenf Grafisi	CoABCMiner	2	9	110.592	%91,79	%85,71	%6,1	11	52	4,7	1,3
Lenf Grafisi	CoABCMiner	3	0	110.613	%93,23	%73,33	%19,9	15	55	3,7	1,3
Lenf Grafisi	CoABCMiner	3	1	110.610	%92,48	%86,67	%5,8	16	87	5,4	1,3
Lenf Grafisi	CoABCMiner	3	2	110.634	%93,99	%66,67	%27,3	11	53	4,8	1,2
Lenf Grafisi	CoABCMiner	3	3	110.628	%90,23	%80,00	%10,2	11	50	4,5	1,3

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Lenf Grafisi	CoABCMiner	3	4	110.600	%93,23	%86,67	%6,6	11	48	4,4	1,3
Lenf Grafisi	CoABCMiner	3	5	110.629	%93,23	%80,00	%13,2	13	68	5,2	1,3
Lenf Grafisi	CoABCMiner	3	6	110.612	%91,73	%86,67	%5,1	18	74	4,1	1,2
Lenf Grafisi	CoABCMiner	3	7	110.651	%91,73	%80,00	%11,7	13	48	3,7	1,2
Lenf Grafisi	CoABCMiner	3	8	110.623	%91,79	%92,86	-1,1%	14	71	5,1	1,3
Lenf Grafisi	CoABCMiner	3	9	110.588	%91,79	%85,71	%6,1	12	60	5	1,3
Lenf Grafisi	CoABCMiner	4	0	110.623	%93,23	%73,33	%19,9	17	85	5	1,3
Lenf Grafisi	CoABCMiner	4	1	110.639	%91,73	%86,67	%5,1	14	65	4,6	1,2
Lenf Grafisi	CoABCMiner	4	2	110.609	%93,99	%66,67	%27,3	13	66	5,1	1,3
Lenf Grafisi	CoABCMiner	4	3	110.615	%90,98	%80,00	%11	13	61	4,7	1,3
Lenf Grafisi	CoABCMiner	4	4	110.623	%91,73	%86,67	%5,1	14	62	4,4	1,3
Lenf Grafisi	CoABCMiner	4	5	110.604	%93,99	%73,33	%20,7	15	74	4,9	1,3
Lenf Grafisi	CoABCMiner	4	6	110.609	%91,73	%80,00	%11,7	15	70	4,7	1,4
Lenf Grafisi	CoABCMiner	4	7	110.641	%93,23	%73,33	%19,9	15	73	4,9	1,2
Lenf Grafisi	CoABCMiner	4	8	110.603	%92,54	%92,86	-0,3%	14	58	4,1	1,3
Lenf Grafisi	CoABCMiner	4	9	110.591	%91,79	%85,71	%6,1	13	59	4,5	1,3
Lenf Grafisi	CoABCMiner	5	0	110.625	%92,48	%73,33	%19,1	12	59	4,9	1,3
Lenf Grafisi	CoABCMiner	5	1	110.634	%91,73	%93,33	-1,6%	13	62	4,8	1,2
Lenf Grafisi	CoABCMiner	5	2	110.617	%93,99	%66,67	%27,3	10	50	5	1,3
Lenf Grafisi	CoABCMiner	5	3	110.625	%90,23	%93,33	-3,1%	15	77	5,1	1,2
Lenf Grafisi	CoABCMiner	5	4	110.622	%93,23	%93,33	-0,1%	14	66	4,7	1,3
Lenf Grafisi	CoABCMiner	5	5	110.612	%92,48	%66,67	%25,8	14	68	4,9	1,3
Lenf Grafisi	CoABCMiner	5	6	110.630	%92,48	%86,67	%5,8	17	84	4,9	1,3
Lenf Grafisi	CoABCMiner	5	7	110.655	%91,73	%86,67	%5,1	12	54	4,5	1,2
Lenf Grafisi	CoABCMiner	5	8	110.610	%92,54	%92,86	-0,3%	17	83	4,9	1,2
Lenf Grafisi	CoABCMiner	5	9	110.587	%91,79	%85,71	%6,1	11	48	4,4	1,1
Lenf Grafisi	CORE	1	0	1.964.439	%90,98	%86,67	%4,3	8	37	4,6	41,4
Lenf Grafisi	CORE	1	1	1.965.737	%87,97	%60,00	%28	14	60	4,3	40,3
Lenf Grafisi	CORE	1	2	1.963.105	%87,97	%66,67	%21,3	10	42	4,2	43,3
Lenf Grafisi	CORE	1	3	1.964.948	%89,47	%80,00	%9,5	12	42	3,5	37,1
Lenf Grafisi	CORE	1	4	1.963.650	%90,98	%86,67	%4,3	13	76	5,8	41
Lenf Grafisi	CORE	1	5	1.963.958	%89,47	%53,33	%36,1	12	68	5,7	43,5
Lenf Grafisi	CORE	1	6	1.966.298	%86,47	%86,67	-0,2%	13	49	3,8	38,5
Lenf Grafisi	CORE	1	7	1.966.983	%90,98	%73,33	%17,6	7	33	4,7	40,8
Lenf Grafisi	CORE	1	8	1.965.149	%86,57	%92,86	-6,3%	8	37	4,6	38,3
Lenf Grafisi	CORE	1	9	1.964.154	%87,31	%78,57	%8,7	11	53	4,8	41,8
Lenf Grafisi	CORE	2	0	-	%87,22	%46,67	%40,6	10	47	4,7	39
Lenf Grafisi	CORE	2	1	-	%90,23	%73,33	%16,9	9	43	4,8	41,6
Lenf Grafisi	CORE	2	2	-	%90,98	%66,67	%24,3	8	42	5,3	40,7
Lenf Grafisi	CORE	2	3	-	%89,47	%66,67	%22,8	13	64	4,9	40,3
Lenf Grafisi	CORE	2	4	-	%90,23	%80,00	%10,2	14	73	5,2	37
Lenf Grafisi	CORE	2	5	-	%89,47	%66,67	%22,8	13	63	4,8	39,2
Lenf Grafisi	CORE	2	6	-	%87,97	%93,33	-5,4%	10	44	4,4	43,1
Lenf Grafisi	CORE	2	7	-	%88,72	%66,67	%22,1	8	36	4,5	41,7
Lenf Grafisi	CORE	2	8	-	%87,31	%100	-12,7%	7	35	5	41,1
Lenf Grafisi	CORE	2	9	-	%87,31	%92,86	-5,5%	13	56	4,3	42,8
Lenf Grafisi	CORE	3	0	-	%87,97	%93,33	-5,4%	12	65	5,4	40,2
Lenf Grafisi	CORE	3	1	-	%89,47	%80,00	%9,5	12	55	4,6	39,3
Lenf Grafisi	CORE	3	2	-	%91,73	%66,67	%25,1	10	51	5,1	41,1
Lenf Grafisi	CORE	3	3	-	%87,22	%73,33	%13,9	9	42	4,7	40,6
Lenf Grafisi	CORE	3	4	-	%87,97	%86,67	%1,3	10	54	5,4	37,3
Lenf Grafisi	CORE	3	5	-	%89,47	%80,00	%9,5	12	49	4,1	39,3
Lenf Grafisi	CORE	3	6	-	%89,47	%86,67	%2,8	13	57	4,4	36,5
Lenf Grafisi	CORE	3	7	-	%90,23	%73,33	%16,9	9	52	5,8	40,6
Lenf Grafisi	CORE	3	8	-	%88,81	%92,86	-4,1%	8	36	4,5	38,8
Lenf Grafisi	CORE	3	9	-	%89,55	%92,86	-3,3%	10	42	4,2	38,7
Lenf Grafisi	CORE	4	0	-	%87,97	%80,00	%8	11	59	5,4	38,9
Lenf Grafisi	CORE	4	1	-	%89,47	%86,67	%2,8	13	60	4,6	43,2
Lenf Grafisi	CORE	4	2	-	%92,48	%73,33	%19,1	10	49	4,9	42,8
Lenf Grafisi	CORE	4	3	-	%86,47	%80,00	%6,5	11	53	4,8	39,7
Lenf Grafisi	CORE	4	4	-	%89,47	%66,67	%22,8	13	57	4,4	40,2
Lenf Grafisi	CORE	4	5	-	%89,47	%73,33	%16,1	12	47	3,9	38,9
Lenf Grafisi	CORE	4	6	-	%87,22	%86,67	%0,6	10	49	4,9	39,3
Lenf Grafisi	CORE	4	7	-	%92,48	%60,00	%32,5	13	71	5,5	43,8
Lenf Grafisi	CORE	4	8	-	%86,57	%92,86	-6,3%	12	58	4,8	45,1
Lenf Grafisi	CORE	4	9	-	%89,55	%85,71	%3,8	14	54	3,9	40,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Lenf Grafisi	CORE	5	0	-	%90,23	%86,67	%3,6	9	42	4,7	39
Lenf Grafisi	CORE	5	1	-	%89,47	%80,00	%9,5	14	65	4,6	35,2
Lenf Grafisi	CORE	5	2	-	%93,99	%66,67	%27,3	13	73	5,6	42,5
Lenf Grafisi	CORE	5	3	-	%88,72	%80,00	%8,7	10	47	4,7	40,2
Lenf Grafisi	CORE	5	4	-	%86,47	%73,33	%13,1	9	40	4,4	38,4
Lenf Grafisi	CORE	5	5	-	%90,23	%86,67	%3,6	11	67	6,1	40
Lenf Grafisi	CORE	5	6	-	%88,72	%86,67	%2,1	12	54	4,5	40,6
Lenf Grafisi	CORE	5	7	-	%88,72	%73,33	%15,4	10	53	5,3	42,5
Lenf Grafisi	CORE	5	8	-	%88,81	%78,57	%10,2	14	71	5,1	42,2
Lenf Grafisi	CORE	5	9	-	%88,81	%100	-11,2%	10	46	4,6	37,4
Lenf Grafisi	HIDER	1	0	-	%78,20	%60,00	%18,2	2	7	3,5	3
Lenf Grafisi	HIDER	1	1	-	%84,20	%73,30	%10,9	4	13	3,3	4
Lenf Grafisi	HIDER	1	2	-	%82,70	%66,70	%16	3	12	4	4
Lenf Grafisi	HIDER	1	3	-	%77,40	%73,30	%4,1	2	6	3	3
Lenf Grafisi	HIDER	1	4	-	%81,20	%86,70	-5,5%	3	13	4,3	4
Lenf Grafisi	HIDER	1	5	-	%82,70	%73,30	%9,4	3	12	4	4
Lenf Grafisi	HIDER	1	6	-	%78,20	%66,70	%11,5	2	6	3	3
Lenf Grafisi	HIDER	1	7	-	%82,70	%66,70	%16	3	11	3,7	4
Lenf Grafisi	HIDER	1	8	-	%77,60	%92,90	-15,3%	3	9	3	4
Lenf Grafisi	HIDER	1	9	-	%79,10	%78,60	%0,5	3	9	3	3
Lenf Grafisi	HIDER	2	0	-	%76,70	%60,00	%16,7	2	8	4	3
Lenf Grafisi	HIDER	2	1	-	%84,20	%80,00	%4,2	5	16	3,2	4
Lenf Grafisi	HIDER	2	2	-	%82,70	%66,70	%16	3	12	4	4
Lenf Grafisi	HIDER	2	3	-	%78,90	%73,30	%5,6	3	9	3	3
Lenf Grafisi	HIDER	2	4	-	%83,50	%86,70	-3,2%	5	14	2,8	4
Lenf Grafisi	HIDER	2	5	-	%82,70	%73,30	%9,4	3	13	4,3	4
Lenf Grafisi	HIDER	2	6	-	%78,20	%66,70	%11,5	2	7	3,5	3
Lenf Grafisi	HIDER	2	7	-	%82,70	%66,70	%16	3	10	3,3	4
Lenf Grafisi	HIDER	2	8	-	%82,80	%78,60	%4,2	4	14	3,5	4
Lenf Grafisi	HIDER	2	9	-	%78,40	%78,60	-0,2%	3	8	2,7	3
Lenf Grafisi	HIDER	3	0	-	%78,20	%60,00	%18,2	2	6	3	3
Lenf Grafisi	HIDER	3	1	-	%84,20	%80,00	%4,2	5	20	4	4
Lenf Grafisi	HIDER	3	2	-	%82,70	%66,70	%16	3	11	3,7	4
Lenf Grafisi	HIDER	3	3	-	%77,40	%73,30	%4,1	3	9	3	3
Lenf Grafisi	HIDER	3	4	-	%82,70	%80,00	%2,7	4	14	3,5	4
Lenf Grafisi	HIDER	3	5	-	%82,70	%73,30	%9,4	3	12	4	4
Lenf Grafisi	HIDER	3	6	-	%77,40	%66,70	%10,7	2	7	3,5	3
Lenf Grafisi	HIDER	3	7	-	%82,70	%73,30	%9,4	3	11	3,7	4
Lenf Grafisi	HIDER	3	8	-	%81,30	%78,60	%2,7	3	10	3,3	4
Lenf Grafisi	HIDER	3	9	-	%78,40	%78,60	-0,2%	3	8	2,7	3
Lenf Grafisi	HIDER	4	0	-	%82,70	%66,70	%16	3	11	3,7	3
Lenf Grafisi	HIDER	4	1	-	%81,20	%86,70	-5,5%	3	12	4	4
Lenf Grafisi	HIDER	4	2	-	%82,70	%73,30	%9,4	3	13	4,3	4
Lenf Grafisi	HIDER	4	3	-	%78,90	%66,70	%12,2	3	10	3,3	3
Lenf Grafisi	HIDER	4	4	-	%82,70	%86,70	-4,0%	4	15	3,8	4
Lenf Grafisi	HIDER	4	5	-	%82,70	%73,30	%9,4	3	13	4,3	4
Lenf Grafisi	HIDER	4	6	-	%78,20	%66,70	%11,5	2	6	3	3
Lenf Grafisi	HIDER	4	7	-	%84,20	%60,00	%24,2	4	12	3	4
Lenf Grafisi	HIDER	4	8	-	%83,60	%92,90	-9,3%	4	14	3,5	4
Lenf Grafisi	HIDER	4	9	-	%78,40	%78,60	-0,2%	3	9	3	3
Lenf Grafisi	HIDER	5	0	-	%83,50	%60,00	%23,5	4	10	2,5	3
Lenf Grafisi	HIDER	5	1	-	%85,00	%73,30	%11,7	5	14	2,8	4
Lenf Grafisi	HIDER	5	2	-	%82,70	%66,70	%16	3	11	3,7	4
Lenf Grafisi	HIDER	5	3	-	%80,50	%66,70	%13,8	3	7	2,3	3
Lenf Grafisi	HIDER	5	4	-	%81,20	%86,70	-5,5%	3	13	4,3	4
Lenf Grafisi	HIDER	5	5	-	%84,20	%73,30	%10,9	4	12	3	4
Lenf Grafisi	HIDER	5	6	-	%77,40	%66,70	%10,7	2	8	4	3
Lenf Grafisi	HIDER	5	7	-	%82,70	%60,00	%22,7	3	11	3,7	4
Lenf Grafisi	HIDER	5	8	-	%84,30	%85,70	-1,4%	5	14	2,8	4
Lenf Grafisi	HIDER	5	9	-	%78,40	%78,60	-0,2%	3	9	3	3
Lenf Grafisi	LDWPSO	1	0	80.030	%84,96	%73,33	%11,6	5	9	1,8	318,4
Lenf Grafisi	LDWPSO	1	1	100.062	%84,96	%86,67	-1,7%	6	13	2,2	323,4
Lenf Grafisi	LDWPSO	1	2	100.059	%87,97	%66,67	%21,3	6	11	1,8	316,3
Lenf Grafisi	LDWPSO	1	3	100.056	%87,97	%60,00	%28	6	13	2,2	540,7
Lenf Grafisi	LDWPSO	1	4	80.032	%84,96	%80,00	%5	5	9	1,8	497,2
Lenf Grafisi	LDWPSO	1	5	100.045	%84,96	%60,00	%25	6	9	1,5	324,9

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Lenf Grafisi	LDWPSO	1	6	100.056	%84,21	%80,00	%4,2	6	13	2,2	479,9
Lenf Grafisi	LDWPSO	1	7	80.027	%85,71	%73,33	%12,4	5	7	1,4	1.075,7
Lenf Grafisi	LDWPSO	1	8	100.046	%83,58	%42,86	%40,7	6	10	1,7	328,2
Lenf Grafisi	LDWPSO	1	9	100.059	%88,81	%28,57	%60,2	6	12	2	1.083,5
Lenf Grafisi	LDWPSO	2	0	80.032	%79,70	%73,33	%6,4	5	8	1,6	347,8
Lenf Grafisi	LDWPSO	2	1	100.036	%80,45	%60,00	%20,5	6	11	1,8	379,9
Lenf Grafisi	LDWPSO	2	2	80.033	%78,95	%60,00	%18,9	5	9	1,8	1.003
Lenf Grafisi	LDWPSO	2	3	100.058	%83,46	%73,33	%10,1	6	12	2	328,4
Lenf Grafisi	LDWPSO	2	4	100.037	%81,95	%86,67	-4,7%	6	11	1,8	292,7
Lenf Grafisi	LDWPSO	2	5	100.035	%81,20	%73,33	%7,9	6	9	1,5	1.061,1
Lenf Grafisi	LDWPSO	2	6	100.049	%86,47	%93,33	-6,9%	6	11	1,8	1.122,4
Lenf Grafisi	LDWPSO	2	7	100.040	%84,21	%66,67	%17,5	6	9	1,5	315,1
Lenf Grafisi	LDWPSO	2	8	80.045	%82,09	%42,86	%39,2	5	9	1,8	545,3
Lenf Grafisi	LDWPSO	2	9	100.055	%87,31	%50,00	%37,3	6	12	2	341,7
Lenf Grafisi	LDWPSO	3	0	100.043	%85,71	%53,33	%32,4	6	10	1,7	551,9
Lenf Grafisi	LDWPSO	3	1	80.038	%78,95	%73,33	%5,6	5	9	1,8	436,1
Lenf Grafisi	LDWPSO	3	2	80.022	%80,45	%73,33	%7,1	5	7	1,4	299,1
Lenf Grafisi	LDWPSO	3	3	80.042	%75,94	%73,33	%2,6	5	9	1,8	285,2
Lenf Grafisi	LDWPSO	3	4	80.035	%79,70	%86,67	-7,0%	5	9	1,8	304,6
Lenf Grafisi	LDWPSO	3	5	80.041	%83,46	%53,33	%30,1	4	7	1,8	324
Lenf Grafisi	LDWPSO	3	6	80.022	%78,20	%73,33	%4,9	4	5	1,3	1.013,7
Lenf Grafisi	LDWPSO	3	7	80.044	%84,21	%73,33	%10,9	5	9	1,8	306,3
Lenf Grafisi	LDWPSO	3	8	100.054	%82,84	%100	-17,2%	6	12	2	315,6
Lenf Grafisi	LDWPSO	3	9	80.034	%78,36	%64,29	%14,1	4	6	1,5	316,5
Lenf Grafisi	LDWPSO	4	0	100.042	%85,71	%66,67	%19	6	10	1,7	320,5
Lenf Grafisi	LDWPSO	4	1	100.086	%84,96	%93,33	-8,4%	6	12	2	279,1
Lenf Grafisi	LDWPSO	4	2	100.047	%84,21	%73,33	%10,9	6	13	2,2	355,1
Lenf Grafisi	LDWPSO	4	3	100.041	%86,47	%46,67	%39,8	6	11	1,8	345
Lenf Grafisi	LDWPSO	4	4	100.061	%85,71	%86,67	-1,0%	6	12	2	261,6
Lenf Grafisi	LDWPSO	4	5	100.042	%87,22	%46,67	%40,6	6	8	1,3	546,8
Lenf Grafisi	LDWPSO	4	6	100.064	%85,71	%86,67	-1,0%	6	14	2,3	351,5
Lenf Grafisi	LDWPSO	4	7	100.042	%83,46	%73,33	%10,1	6	10	1,7	312,9
Lenf Grafisi	LDWPSO	4	8	100.056	%82,09	%85,71	-3,6%	6	13	2,2	282,5
Lenf Grafisi	LDWPSO	4	9	80.033	%82,09	%71,43	%10,7	5	9	1,8	279,9
Lenf Grafisi	LDWPSO	5	0	80.023	%87,97	%60,00	%28	5	7	1,4	258,7
Lenf Grafisi	LDWPSO	5	1	100.051	%84,21	%86,67	-2,5%	6	13	2,2	279,1
Lenf Grafisi	LDWPSO	5	2	100.049	%87,22	%66,67	%20,6	6	10	1,7	273,5
Lenf Grafisi	LDWPSO	5	3	100.064	%87,97	%40,00	%48	6	14	2,3	273,1
Lenf Grafisi	LDWPSO	5	4	100.057	%82,71	%80,00	%2,7	6	12	2	273,9
Lenf Grafisi	LDWPSO	5	5	100.041	%87,97	%60,00	%28	6	10	1,7	294,8
Lenf Grafisi	LDWPSO	5	6	100.065	%85,71	%86,67	-1,0%	6	14	2,3	286,9
Lenf Grafisi	LDWPSO	5	7	100.039	%84,96	%73,33	%11,6	6	9	1,5	286,5
Lenf Grafisi	LDWPSO	5	8	100.053	%85,82	%42,86	%43	6	12	2	283
Lenf Grafisi	LDWPSO	5	9	80.055	%83,58	%57,14	%26,4	5	11	2,2	287,9
Lenf Grafisi	PGIRLA	1	0	-	%85,71	%80,00	%5,7	20	190	9,5	1
Lenf Grafisi	PGIRLA	1	1	-	%84,96	%66,67	%18,3	20	160	8	1
Lenf Grafisi	PGIRLA	1	2	-	%87,22	%73,33	%13,9	20	172	8,6	1
Lenf Grafisi	PGIRLA	1	3	-	%87,97	%66,67	%21,3	20	171	8,6	1
Lenf Grafisi	PGIRLA	1	4	-	%84,21	%93,33	-9,1%	20	180	9	1
Lenf Grafisi	PGIRLA	1	5	-	%84,21	%73,33	%10,9	20	199	10	1
Lenf Grafisi	PGIRLA	1	6	-	%86,47	%73,33	%13,1	20	165	8,3	1
Lenf Grafisi	PGIRLA	1	7	-	%83,46	%73,33	%10,1	20	175	8,8	1
Lenf Grafisi	PGIRLA	1	8	-	%83,58	%92,86	-9,3%	20	172	8,6	2
Lenf Grafisi	PGIRLA	1	9	-	%82,84	%92,86	-10,0%	20	174	8,7	1
Lenf Grafisi	PGIRLA	2	0	-	%85,71	%80,00	%5,7	20	166	8,3	1
Lenf Grafisi	PGIRLA	2	1	-	%84,21	%73,33	%10,9	20	185	9,3	1
Lenf Grafisi	PGIRLA	2	2	-	%86,47	%73,33	%13,1	20	168	8,4	1
Lenf Grafisi	PGIRLA	2	3	-	%84,96	%73,33	%11,6	20	184	9,2	1
Lenf Grafisi	PGIRLA	2	4	-	%84,21	%93,33	-9,1%	20	175	8,8	1
Lenf Grafisi	PGIRLA	2	5	-	%84,21	%73,33	%10,9	20	179	9	1
Lenf Grafisi	PGIRLA	2	6	-	%83,46	%73,33	%10,1	20	168	8,4	1
Lenf Grafisi	PGIRLA	2	7	-	%84,21	%73,33	%10,9	20	178	8,9	1
Lenf Grafisi	PGIRLA	2	8	-	%85,82	%71,43	%14,4	20	172	8,6	2
Lenf Grafisi	PGIRLA	2	9	-	%83,58	%92,86	-9,3%	20	183	9,2	1
Lenf Grafisi	PGIRLA	3	0	-	%85,71	%33,33	%52,4	20	172	8,6	1
Lenf Grafisi	PGIRLA	3	1	-	%84,21	%86,67	-2,5%	20	162	8,1	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Lenf Grafisi	PGIRLA	3	2	-	%83,46	%66,67	%16,8	20	181	9,1	1
Lenf Grafisi	PGIRLA	3	3	-	%84,96	%73,33	%11,6	20	159	8	1
Lenf Grafisi	PGIRLA	3	4	-	%84,21	%80,00	%4,2	20	169	8,5	1
Lenf Grafisi	PGIRLA	3	5	-	%80,45	%80,00	%0,5	20	176	8,8	1
Lenf Grafisi	PGIRLA	3	6	-	%84,21	%86,67	-2,5%	20	160	8	1
Lenf Grafisi	PGIRLA	3	7	-	%87,22	%73,33	%13,9	20	178	8,9	1
Lenf Grafisi	PGIRLA	3	8	-	%82,84	%85,71	-2,9%	20	182	9,1	2
Lenf Grafisi	PGIRLA	3	9	-	%79,85	%71,43	%8,4	20	190	9,5	1
Lenf Grafisi	PGIRLA	4	0	-	%79,70	%80,00	-0,3%	20	176	8,8	1
Lenf Grafisi	PGIRLA	4	1	-	%82,71	%73,33	%9,4	20	191	9,6	1
Lenf Grafisi	PGIRLA	4	2	-	%85,71	%60,00	%25,7	20	159	8	1
Lenf Grafisi	PGIRLA	4	3	-	%84,96	%86,67	-1,7%	20	172	8,6	1
Lenf Grafisi	PGIRLA	4	4	-	%84,21	%86,67	-2,5%	20	175	8,8	1
Lenf Grafisi	PGIRLA	4	5	-	%78,20	%73,33	%4,9	20	191	9,6	1
Lenf Grafisi	PGIRLA	4	6	-	%84,21	%93,33	-9,1%	20	179	9	1
Lenf Grafisi	PGIRLA	4	7	-	%81,95	%66,67	%15,3	20	169	8,5	1
Lenf Grafisi	PGIRLA	4	8	-	%78,36	%71,43	%6,9	20	183	9,2	2
Lenf Grafisi	PGIRLA	4	9	-	%79,10	%50,00	%29,1	20	167	8,4	1
Lenf Grafisi	PGIRLA	5	0	-	%86,47	%46,67	%39,8	20	183	9,2	1
Lenf Grafisi	PGIRLA	5	1	-	%84,21	%73,33	%10,9	20	178	8,9	1
Lenf Grafisi	PGIRLA	5	2	-	%82,71	%66,67	%16	20	169	8,5	1
Lenf Grafisi	PGIRLA	5	3	-	%86,47	%73,33	%13,1	20	190	9,5	1
Lenf Grafisi	PGIRLA	5	4	-	%85,71	%80,00	%5,7	20	174	8,7	1
Lenf Grafisi	PGIRLA	5	5	-	%87,22	%73,33	%13,9	20	161	8,1	1
Lenf Grafisi	PGIRLA	5	6	-	%83,46	%86,67	-3,2%	20	188	9,4	1
Lenf Grafisi	PGIRLA	5	7	-	%85,71	%86,67	-1,0%	20	158	7,9	1
Lenf Grafisi	PGIRLA	5	8	-	%85,82	%92,86	-7,0%	20	182	9,1	2
Lenf Grafisi	PGIRLA	5	9	-	%81,34	%71,43	%9,9	20	160	8	1
Lenf Grafisi	SIA	1	0	-	%100	%60,00	%40	32	148	4,6	2
Lenf Grafisi	SIA	1	1	-	%100	%80,00	%20	29	155	5,3	1
Lenf Grafisi	SIA	1	2	-	%100	%80,00	%20	30	111	3,7	1
Lenf Grafisi	SIA	1	3	-	%100	%93,33	%6,7	35	154	4,4	2
Lenf Grafisi	SIA	1	4	-	%100	%86,67	%13,3	37	118	3,2	2
Lenf Grafisi	SIA	1	5	-	%100	%100	%0	35	142	4,1	2
Lenf Grafisi	SIA	1	6	-	%100	%80,00	%20	33	163	4,9	1
Lenf Grafisi	SIA	1	7	-	%100	%73,33	%26,7	32	155	4,8	1
Lenf Grafisi	SIA	1	8	-	%100	%85,71	%14,3	35	171	4,9	1
Lenf Grafisi	SIA	1	9	-	%100	%100	%0	34	153	4,5	2
Lenf Grafisi	SIA	2	0	-	%100	%60,00	%40	36	114	3,2	2
Lenf Grafisi	SIA	2	1	-	%100	%86,67	%13,3	35	109	3,1	2
Lenf Grafisi	SIA	2	2	-	%100	%66,67	%33,3	26	116	4,5	1
Lenf Grafisi	SIA	2	3	-	%100	%93,33	%6,7	33	105	3,2	1
Lenf Grafisi	SIA	2	4	-	%100	%80,00	%20	33	113	3,4	1
Lenf Grafisi	SIA	2	5	-	%100	%80,00	%20	31	163	5,3	1
Lenf Grafisi	SIA	2	6	-	%100	%93,33	%6,7	34	143	4,2	1
Lenf Grafisi	SIA	2	7	-	%100	%53,33	%46,7	32	141	4,4	1
Lenf Grafisi	SIA	2	8	-	%100	%71,43	%28,6	35	169	4,8	1
Lenf Grafisi	SIA	2	9	-	%100	%100	%0	32	137	4,3	1
Lenf Grafisi	SIA	3	0	-	%100	%60,00	%40	29	145	5	1
Lenf Grafisi	SIA	3	1	-	%100	%86,67	%13,3	36	145	4	1
Lenf Grafisi	SIA	3	2	-	%100	%73,33	%26,7	30	127	4,2	1
Lenf Grafisi	SIA	3	3	-	%100	%93,33	%6,7	33	153	4,6	1
Lenf Grafisi	SIA	3	4	-	%100	%86,67	%13,3	34	149	4,4	1
Lenf Grafisi	SIA	3	5	-	%100	%86,67	%13,3	36	139	3,9	2
Lenf Grafisi	SIA	3	6	-	%100	%86,67	%13,3	38	131	3,4	2
Lenf Grafisi	SIA	3	7	-	%100	%60,00	%40	27	155	5,7	1
Lenf Grafisi	SIA	3	8	-	%100	%92,86	%7,1	34	113	3,3	1
Lenf Grafisi	SIA	3	9	-	%100	%92,86	%7,1	35	140	4	2
Lenf Grafisi	SIA	4	0	-	%100	%73,33	%26,7	35	148	4,2	2
Lenf Grafisi	SIA	4	1	-	%100	%80,00	%20	38	149	3,9	2
Lenf Grafisi	SIA	4	2	-	%100	%60,00	%40	26	180	6,9	1
Lenf Grafisi	SIA	4	3	-	%100	%86,67	%13,3	36	117	3,3	2
Lenf Grafisi	SIA	4	4	-	%100	%93,33	%6,7	34	125	3,7	2
Lenf Grafisi	SIA	4	5	-	%100	%100	%0	29	132	4,6	1
Lenf Grafisi	SIA	4	6	-	%100	%93,33	%6,7	30	154	5,1	1
Lenf Grafisi	SIA	4	7	-	%100	%73,33	%26,7	29	122	4,2	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Lenf Grafisi	SIA	4	8	-	%100	%85,71	%14,3	35	133	3,8	2
Lenf Grafisi	SIA	4	9	-	%100	%85,71	%14,3	37	139	3,8	2
Lenf Grafisi	SIA	5	0	-	%100	%73,33	%26,7	30	140	4,7	2
Lenf Grafisi	SIA	5	1	-	%100	%80,00	%20	33	150	4,5	2
Lenf Grafisi	SIA	5	2	-	%100	%73,33	%26,7	29	148	5,1	1
Lenf Grafisi	SIA	5	3	-	%100	%86,67	%13,3	31	151	4,9	2
Lenf Grafisi	SIA	5	4	-	%100	%80,00	%20	34	137	4	2
Lenf Grafisi	SIA	5	5	-	%100	%73,33	%26,7	34	143	4,2	2
Lenf Grafisi	SIA	5	6	-	%100	%100	%0	32	146	4,6	1
Lenf Grafisi	SIA	5	7	-	%100	%73,33	%26,7	29	143	4,9	1
Lenf Grafisi	SIA	5	8	-	%100	%85,71	%14,3	34	158	4,6	1
Lenf Grafisi	SIA	5	9	-	%100	%85,71	%14,3	33	152	4,6	2
Mantar	ABCMiner	1	0	60.469	%94,27	%93,48	%0,8	4	4	1	15.672,1
Mantar	ABCMiner	1	1	80.637	%96,24	%95,94	%0,3	5	8	1,6	16.840,1
Mantar	ABCMiner	1	2	60.486	%91,92	%92,99	-1,1%	4	6	1,5	14.542,3
Mantar	ABCMiner	1	3	60.470	%95,29	%95,08	%0,2	4	6	1,5	13.834,9
Mantar	ABCMiner	1	4	60.462	%89,70	%47,54	%42,2	3	2	0,7	12.386,6
Mantar	ABCMiner	1	5	60.475	%95,47	%95,94	-0,5%	3	5	1,7	12.296
Mantar	ABCMiner	1	6	60.471	%93,19	%92,86	%0,3	4	5	1,3	13.102,8
Mantar	ABCMiner	1	7	60.459	%93,96	%94,34	-0,4%	4	4	1	12.026
Mantar	ABCMiner	1	8	60.483	%94,23	%93,84	%0,4	4	5	1,3	13.355,9
Mantar	ABCMiner	1	9	60.471	%89,39	%89,16	%0,2	4	5	1,3	12.989,8
Mantar	ABCMiner	2	0	60.473	%95,09	%95,45	-0,4%	3	4	1,3	15.481,4
Mantar	ABCMiner	2	1	60.480	%94,16	%87,58	%6,6	4	6	1,5	15.478,3
Mantar	ABCMiner	2	2	60.474	%93,56	%93,97	-0,4%	4	6	1,5	12.517,7
Mantar	ABCMiner	2	3	60.486	%94,17	%94,34	-0,2%	4	5	1,3	12.857,8
Mantar	ABCMiner	2	4	60.471	%95,58	%49,01	%46,6	4	6	1,5	13.269,8
Mantar	ABCMiner	2	5	60.473	%93,68	%94,34	-0,7%	3	4	1,3	12.390,8
Mantar	ABCMiner	2	6	60.489	%94,15	%85,22	%8,9	4	5	1,3	12.149,9
Mantar	ABCMiner	2	7	60.457	%95,60	%94,83	%0,8	3	5	1,7	11.924,4
Mantar	ABCMiner	2	8	60.485	%94,23	%93,84	%0,4	4	4	1	11.743,6
Mantar	ABCMiner	2	9	60.460	%93,64	%93,23	%0,4	4	6	1,5	12.326,4
Mantar	ABCMiner	3	0	60.474	%93,69	%94,22	-0,5%	4	6	1,5	15.451
Mantar	ABCMiner	3	1	60.478	%94,02	%93,73	%0,3	4	4	1	15.246,6
Mantar	ABCMiner	3	2	60.481	%93,98	%94,10	-0,1%	3	3	1	13.536,6
Mantar	ABCMiner	3	3	60.481	%94,04	%93,60	%0,4	4	4	1	12.538,5
Mantar	ABCMiner	3	4	60.462	%93,83	%73,28	%20,6	4	7	1,8	13.259,2
Mantar	ABCMiner	3	5	60.487	%94,27	%93,47	%0,8	4	4	1	11.789,4
Mantar	ABCMiner	3	6	60.478	%93,64	%93,23	%0,4	4	6	1,5	12.540
Mantar	ABCMiner	3	7	60.475	%93,56	%93,97	-0,4%	4	6	1,5	12.634,3
Mantar	ABCMiner	3	8	60.497	%95,47	%96,43	-1,0%	4	6	1,5	11.726,9
Mantar	ABCMiner	3	9	60.475	%93,86	%93,23	%0,6	4	7	1,8	12.719,4
Mantar	ABCMiner	4	0	60.488	%94,27	%93,48	%0,8	4	5	1,3	11.412
Mantar	ABCMiner	4	1	80.654	%95,80	%95,45	%0,4	5	9	1,8	12.581,6
Mantar	ABCMiner	4	2	60.487	%95,24	%95,57	-0,3%	4	6	1,5	11.146,6
Mantar	ABCMiner	4	3	60.478	%93,90	%93,60	%0,3	4	6	1,5	10.952,1
Mantar	ABCMiner	4	4	60.470	%92,37	%89,29	%3,1	4	5	1,3	11.617,9
Mantar	ABCMiner	4	5	60.469	%93,68	%94,34	-0,7%	3	4	1,3	11.569,3
Mantar	ABCMiner	4	6	60.477	%92,59	%92,86	-0,3%	4	7	1,8	12.032,4
Mantar	ABCMiner	4	7	60.469	%95,23	%95,69	-0,5%	4	6	1,5	11.692,1
Mantar	ABCMiner	4	8	60.471	%93,57	%93,84	-0,3%	4	6	1,5	11.631,8
Mantar	ABCMiner	4	9	60.474	%94,00	%93,97	%0	4	4	1	11.096,6
Mantar	ABCMiner	5	0	60.498	%94,27	%93,48	%0,8	4	5	1,3	12.108,7
Mantar	ABCMiner	5	1	80.633	%95,58	%95,20	%0,4	5	9	1,8	13.391,3
Mantar	ABCMiner	5	2	60.477	%93,56	%93,97	-0,4%	4	6	1,5	11.366,1
Mantar	ABCMiner	5	3	80.632	%94,09	%94,10	%0	4	7	1,8	12.759,3
Mantar	ABCMiner	5	4	60.464	%95,09	%47,54	%47,6	3	4	1,3	11.391,9
Mantar	ABCMiner	5	5	60.469	%92,96	%92,49	%0,5	4	6	1,5	12.164
Mantar	ABCMiner	5	6	60.459	%93,64	%93,23	%0,4	4	6	1,5	11.459,1
Mantar	ABCMiner	5	7	60.461	%93,56	%93,97	-0,4%	4	6	1,5	11.536
Mantar	ABCMiner	5	8	80.662	%97,32	%97,04	%0,3	5	9	1,8	12.120,8
Mantar	ABCMiner	5	9	60.493	%94,26	%93,60	%0,7	4	5	1,3	11.336,3
Mantar	C4.5	-	1	-	%99,81	%99,75	%0,1	15	29	1,9	1,5
Mantar	C4.5	-	2	-	%99,79	%99,88	-0,1%	18	36	2	1,5
Mantar	C4.5	-	3	-	%99,79	%99,88	-0,1%	15	31	2,1	1,5
Mantar	C4.5	-	4	-	%99,81	%99,75	%0,1	18	36	2	1,5

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Mantar	C4.5	-	5	-	%99,81	%99,75	%0,1	15	29	1,9	1,5
Mantar	C4.5	-	6	-	%99,79	%99,88	-0,1%	15	29	1,9	1,5
Mantar	C4.5	-	7	-	%99,90	%99,88	%0	18	32	1,8	1,5
Mantar	C4.5	-	8	-	%99,78	%100	-0,2%	17	32	1,9	1,5
Mantar	C4.5	-	9	-	%99,86	%99,26	%0,6	15	31	2,1	1,5
Mantar	C4.5	-	10	-	%99,78	%100	-0,2%	17	32	1,9	1,5
Mantar	CoABCMiner	1	0	110.493	%99,77	%99,63	%0,1	7	36	5,1	145
Mantar	CoABCMiner	1	1	110.497	%99,97	%99,88	%0,1	8	44	5,5	154,9
Mantar	CoABCMiner	1	2	110.520	%99,90	%99,88	%0	7	26	3,7	154,1
Mantar	CoABCMiner	1	3	110.497	%99,75	%99,88	-0,1%	4	17	4,3	148,9
Mantar	CoABCMiner	1	4	110.498	%99,96	%99,88	%0,1	8	26	3,3	157,3
Mantar	CoABCMiner	1	5	110.500	%99,89	%100	-0,1%	9	43	4,8	152,5
Mantar	CoABCMiner	1	6	110.512	%99,96	%100	%0	7	24	3,4	150,9
Mantar	CoABCMiner	1	7	110.503	%99,96	%100	%0	8	41	5,1	157,2
Mantar	CoABCMiner	1	8	110.516	%99,71	%99,38	%0,3	6	30	5	171,8
Mantar	CoABCMiner	1	9	110.504	%99,60	%99,63	%0	7	32	4,6	169,1
Mantar	CoABCMiner	2	0	110.513	%99,97	%99,88	%0,1	11	62	5,6	136,2
Mantar	CoABCMiner	2	1	110.514	%99,78	%99,63	%0,2	5	26	5,2	142,4
Mantar	CoABCMiner	2	2	110.499	%99,77	%99,75	%0	6	27	4,5	149,2
Mantar	CoABCMiner	2	3	110.515	%99,90	%99,88	%0	9	42	4,7	144,2
Mantar	CoABCMiner	2	4	110.499	%99,88	%99,88	%0	11	47	4,3	147,4
Mantar	CoABCMiner	2	5	110.505	%99,95	%100	-0,1%	9	34	3,8	144
Mantar	CoABCMiner	2	6	110.508	%99,95	%100	-0,1%	10	57	5,7	148,4
Mantar	CoABCMiner	2	7	110.505	%99,84	%100	-0,2%	8	35	4,4	154,4
Mantar	CoABCMiner	2	8	110.501	%100	%100	%0	8	26	3,3	164,6
Mantar	CoABCMiner	2	9	110.520	%99,96	%100	%0	5	20	4	165,6
Mantar	CoABCMiner	3	0	110.494	%99,56	%99,51	%0,1	9	42	4,7	165,3
Mantar	CoABCMiner	3	1	110.499	%99,71	%99,63	%0,1	9	40	4,4	145,3
Mantar	CoABCMiner	3	2	110.517	%99,92	%99,88	%0	8	37	4,6	142,6
Mantar	CoABCMiner	3	3	110.504	%99,95	%100	-0,1%	6	30	5	147,9
Mantar	CoABCMiner	3	4	110.493	%99,96	%99,88	%0,1	9	35	3,9	144,5
Mantar	CoABCMiner	3	5	110.516	%99,89	%100	-0,1%	11	46	4,2	141,4
Mantar	CoABCMiner	3	6	110.510	%100	%100	%0	8	34	4,3	143
Mantar	CoABCMiner	3	7	110.494	%99,74	%99,88	-0,1%	6	25	4,2	149,1
Mantar	CoABCMiner	3	8	110.499	%99,74	%99,88	-0,1%	8	36	4,5	163,2
Mantar	CoABCMiner	3	9	110.496	%99,74	%99,88	-0,1%	8	30	3,8	161,7
Mantar	CoABCMiner	4	0	110.525	%99,81	%99,75	%0,1	8	32	4	143,5
Mantar	CoABCMiner	4	1	110.495	%99,82	%99,75	%0,1	9	33	3,7	148,4
Mantar	CoABCMiner	4	2	110.501	%99,97	%100	%0	10	49	4,9	149,6
Mantar	CoABCMiner	4	3	110.497	%100	%100	%0	10	43	4,3	147,2
Mantar	CoABCMiner	4	4	110.500	%99,96	%99,88	%0,1	8	39	4,9	146,5
Mantar	CoABCMiner	4	5	110.521	%99,79	%99,88	-0,1%	6	22	3,7	143,3
Mantar	CoABCMiner	4	6	110.523	%99,85	%99,88	%0	10	49	4,9	144,4
Mantar	CoABCMiner	4	7	110.499	%99,63	%100	-0,4%	8	38	4,8	145,5
Mantar	CoABCMiner	4	8	110.512	%99,92	%99,75	%0,2	7	26	3,7	165,7
Mantar	CoABCMiner	4	9	110.491	%99,74	%99,88	-0,1%	7	26	3,7	165,1
Mantar	CoABCMiner	5	0	110.508	%99,90	%99,88	%0	9	30	3,3	146
Mantar	CoABCMiner	5	1	110.491	%99,97	%99,88	%0,1	6	28	4,7	150
Mantar	CoABCMiner	5	2	110.506	%99,97	%99,88	%0,1	7	29	4,1	149,9
Mantar	CoABCMiner	5	3	110.496	%99,90	%99,88	%0	9	40	4,4	149,6
Mantar	CoABCMiner	5	4	110.502	%99,90	%99,88	%0	6	25	4,2	153,3
Mantar	CoABCMiner	5	5	110.514	%99,79	%99,88	-0,1%	10	55	5,5	150,1
Mantar	CoABCMiner	5	6	110.499	%99,79	%99,88	-0,1%	9	35	3,9	147,7
Mantar	CoABCMiner	5	7	110.496	%99,95	%100	-0,1%	8	38	4,8	151,8
Mantar	CoABCMiner	5	8	110.520	%99,92	%99,75	%0,2	8	24	3	162,9
Mantar	CoABCMiner	5	9	110.508	%99,75	%99,88	-0,1%	5	20	4	162,3
Mantar	CORE	1	0	1.963.580	%98,45	%98,16	%0,3	9	48	5,3	3.750,6
Mantar	CORE	1	1	1.964.518	%98,84	%98,65	%0,2	13	72	5,5	3.865,2
Mantar	CORE	1	2	1.963.475	%98,60	%98,77	-0,2%	8	30	3,8	3.709,3
Mantar	CORE	1	3	1.967.308	%98,96	%98,52	%0,4	8	34	4,3	3.754,7
Mantar	CORE	1	4	1.963.934	%99,04	%98,77	%0,3	14	71	5,1	3.851,8
Mantar	CORE	1	5	1.965.291	%99,21	%99,26	-0,1%	12	70	5,8	3.816,1
Mantar	CORE	1	6	1.964.893	%98,30	%98,77	-0,5%	9	37	4,1	3.713,1
Mantar	CORE	1	7	1.963.923	%98,95	%98,65	%0,3	11	53	4,8	3.732,4
Mantar	CORE	1	8	1.965.383	%99,10	%98,77	%0,3	14	71	5,1	3.829,9
Mantar	CORE	1	9	1.963.954	%98,59	%98,40	%0,2	7	31	4,4	3.589,4

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Mantar	CORE	2	0	-	%99,52	%99,39	%0,1	12	55	4,6	3.695,4
Mantar	CORE	2	1	-	%98,48	%98,89	-0,4%	11	62	5,6	3.771,6
Mantar	CORE	2	2	-	%99,67	%99,75	-0,1%	11	57	5,2	3.720,4
Mantar	CORE	2	3	-	%99,06	%98,65	%0,4	3	8	2,7	3.747,7
Mantar	CORE	2	4	-	%99,04	%98,77	%0,3	7	35	5	3.877,7
Mantar	CORE	2	5	-	%99,00	%99,14	-0,1%	3	10	3,3	3.649,7
Mantar	CORE	2	6	-	%99,38	%99,63	-0,2%	3	11	3,7	3.729,5
Mantar	CORE	2	7	-	%98,99	%98,52	%0,5	9	54	6	3.808,4
Mantar	CORE	2	8	-	%99,06	%98,89	%0,2	8	52	6,5	3.838,2
Mantar	CORE	2	9	-	%99,43	%99,26	%0,2	9	46	5,1	3.685,3
Mantar	CORE	3	0	-	%99,03	%98,89	%0,1	7	31	4,4	3.877
Mantar	CORE	3	1	-	%97,63	%97,66	%0	9	37	4,1	3.857,4
Mantar	CORE	3	2	-	%98,96	%99,51	-0,5%	9	48	5,3	3.841
Mantar	CORE	3	3	-	%98,55	%98,28	%0,3	4	16	4	3.801
Mantar	CORE	3	4	-	%97,96	%98,15	-0,2%	6	31	5,2	3.761,7
Mantar	CORE	3	5	-	%99,26	%99,75	-0,5%	14	65	4,6	3.920,6
Mantar	CORE	3	6	-	%98,95	%99,63	-0,7%	7	31	4,4	3.898,2
Mantar	CORE	3	7	-	%98,44	%98,28	%0,2	7	26	3,7	3.772,9
Mantar	CORE	3	8	-	%99,54	%99,01	%0,5	12	62	5,2	3.881
Mantar	CORE	3	9	-	%98,50	%98,28	%0,2	6	30	5	3.296,2
Mantar	CORE	4	0	-	%99,03	%98,89	%0,1	12	50	4,2	3.800,8
Mantar	CORE	4	1	-	%98,50	%98,77	-0,3%	9	40	4,4	3.769,5
Mantar	CORE	4	2	-	%99,08	%98,89	%0,2	12	64	5,3	3.861,2
Mantar	CORE	4	3	-	%98,65	%98,40	%0,2	13	55	4,2	3.694,9
Mantar	CORE	4	4	-	%99,70	%99,75	-0,1%	13	63	4,8	3.766,3
Mantar	CORE	4	5	-	%99,44	%99,14	%0,3	11	56	5,1	3.712,2
Mantar	CORE	4	6	-	%98,77	%99,26	-0,5%	7	33	4,7	3.735,9
Mantar	CORE	4	7	-	%99,06	%98,65	%0,4	7	39	5,6	3.753,1
Mantar	CORE	4	8	-	%98,84	%98,65	%0,2	13	70	5,4	3.845
Mantar	CORE	4	9	-	%98,89	%98,65	%0,2	5	25	5	3.611,1
Mantar	CORE	5	0	-	%99,41	%99,39	%0	12	57	4,8	3.453,5
Mantar	CORE	5	1	-	%99,00	%99,14	-0,1%	12	55	4,6	3.713,8
Mantar	CORE	5	2	-	%99,19	%99,39	-0,2%	14	56	4	3.689,8
Mantar	CORE	5	3	-	%99,10	%98,77	%0,3	12	76	6,3	3.721
Mantar	CORE	5	4	-	%98,32	%98,40	-0,1%	6	32	5,3	3.725,2
Mantar	CORE	5	5	-	%98,81	%98,89	-0,1%	10	52	5,2	3.718,7
Mantar	CORE	5	6	-	%98,95	%99,63	-0,7%	5	18	3,6	3.646,4
Mantar	CORE	5	7	-	%99,06	%98,65	%0,4	14	63	4,5	3.638,6
Mantar	CORE	5	8	-	%98,69	%98,03	%0,7	11	59	5,4	3.583,4
Mantar	CORE	5	9	-	%99,69	%99,88	-0,2%	10	55	5,5	3.661,2
Mantar	HIDER	1	0	-	%95,00	%95,30	-0,3%	6	94	15,7	105
Mantar	HIDER	1	1	-	%95,50	%95,80	-0,3%	6	103	17,2	95
Mantar	HIDER	1	2	-	%94,70	%95,40	-0,7%	6	102	17	101
Mantar	HIDER	1	3	-	%95,10	%94,90	%0,2	5	75	15	92
Mantar	HIDER	1	4	-	%95,80	%96,40	-0,6%	5	78	15,6	100
Mantar	HIDER	1	5	-	%98,20	%98,60	-0,4%	5	76	15,2	94
Mantar	HIDER	1	6	-	%97,40	%96,30	%1,1	5	81	16,2	94
Mantar	HIDER	1	7	-	%95,30	%94,70	%0,6	5	79	15,8	96
Mantar	HIDER	1	8	-	%96,70	%96,10	%0,6	5	75	15	93
Mantar	HIDER	1	9	-	%97,80	%97,20	%0,6	5	77	15,4	93
Mantar	HIDER	2	0	-	%94,60	%93,40	%1,2	4	59	14,8	105
Mantar	HIDER	2	1	-	%94,70	%94,90	-0,2%	4	61	15,3	95
Mantar	HIDER	2	2	-	%91,50	%93,20	-1,7%	4	58	14,5	101
Mantar	HIDER	2	3	-	%96,70	%95,80	%0,9	5	72	14,4	92
Mantar	HIDER	2	4	-	%91,10	%89,80	%1,3	4	63	15,8	100
Mantar	HIDER	2	5	-	%96,70	%96,80	-0,1%	4	61	15,3	94
Mantar	HIDER	2	6	-	%96,20	%96,30	-0,1%	4	56	14	94
Mantar	HIDER	2	7	-	%97,10	%96,50	%0,6	5	76	15,2	96
Mantar	HIDER	2	8	-	%97,30	%97,00	%0,3	5	78	15,6	93
Mantar	HIDER	2	9	-	%94,80	%96,50	-1,7%	4	58	14,5	93
Mantar	HIDER	3	0	-	%96,10	%95,70	%0,4	4	58	14,5	105
Mantar	HIDER	3	1	-	%97,90	%98,50	-0,6%	3	43	14,3	95
Mantar	HIDER	3	2	-	%91,60	%91,60	%0	5	77	15,4	101
Mantar	HIDER	3	3	-	%96,60	%95,60	%1	6	95	15,8	92
Mantar	HIDER	3	4	-	%93,90	%94,50	-0,6%	5	75	15	100
Mantar	HIDER	3	5	-	%96,70	%97,10	-0,4%	5	82	16,4	94

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Mantar	HIDER	3	6	-	%97,20	%96,50	%0,7	4	59	14,8	94
Mantar	HIDER	3	7	-	%97,80	%97,50	%0,3	4	62	15,5	96
Mantar	HIDER	3	8	-	%92,00	%92,10	-0,1%	5	81	16,2	93
Mantar	HIDER	3	9	-	%96,70	%96,30	%0,4	5	78	15,6	93
Mantar	HIDER	4	0	-	%97,00	%97,00	%0	6	101	16,8	105
Mantar	HIDER	4	1	-	%97,70	%97,80	-0,1%	4	63	15,8	95
Mantar	HIDER	4	2	-	%98,20	%98,10	%0,1	5	79	15,8	101
Mantar	HIDER	4	3	-	%97,90	%98,10	-0,2%	3	43	14,3	92
Mantar	HIDER	4	4	-	%96,40	%97,40	-1,0%	4	60	15	100
Mantar	HIDER	4	5	-	%95,30	%95,20	%0,1	5	78	15,6	94
Mantar	HIDER	4	6	-	%95,50	%94,10	%1,4	5	78	15,6	94
Mantar	HIDER	4	7	-	%96,50	%96,10	%0,4	4	61	15,3	96
Mantar	HIDER	4	8	-	%97,90	%97,50	%0,4	6	96	16	93
Mantar	HIDER	4	9	-	%97,40	%97,20	%0,2	4	61	15,3	93
Mantar	HIDER	5	0	-	%93,40	%92,70	%0,7	5	78	15,6	105
Mantar	HIDER	5	1	-	%97,50	%98,00	-0,5%	7	113	16,1	95
Mantar	HIDER	5	2	-	%95,30	%96,50	-1,2%	6	94	15,7	101
Mantar	HIDER	5	3	-	%96,30	%96,50	-0,2%	5	81	16,2	92
Mantar	HIDER	5	4	-	%92,70	%91,90	%0,8	4	60	15	100
Mantar	HIDER	5	5	-	%94,20	%93,70	%0,5	5	82	16,4	94
Mantar	HIDER	5	6	-	%94,00	%93,40	%0,6	4	59	14,8	94
Mantar	HIDER	5	7	-	%96,30	%96,30	%0	4	59	14,8	96
Mantar	HIDER	5	8	-	%97,50	%96,20	%1,3	4	58	14,5	93
Mantar	HIDER	5	9	-	%95,90	%96,10	-0,2%	5	73	14,6	93
Mantar	LDWPSO	1	0	60.013	%92,98	%93,23	-0,3%	4	5	1,3	34.002,8
Mantar	LDWPSO	1	1	60.013	%92,97	%93,36	-0,4%	4	5	1,3	19.331,5
Mantar	LDWPSO	1	2	60.010	%92,86	%94,34	-1,5%	4	5	1,3	19.119,2
Mantar	LDWPSO	1	3	60.010	%93,17	%91,51	%1,7	4	5	1,3	18.735,8
Mantar	LDWPSO	1	4	60.013	%92,92	%93,84	-0,9%	4	5	1,3	19.319,7
Mantar	LDWPSO	1	5	60.010	%93,04	%92,73	%0,3	4	5	1,3	18.059
Mantar	LDWPSO	1	6	60.010	%93,05	%92,61	%0,4	4	5	1,3	19.103
Mantar	LDWPSO	1	7	60.013	%92,94	%93,60	-0,7%	4	5	1,3	18.593,3
Mantar	LDWPSO	1	8	60.013	%93,11	%92,12	%1	4	5	1,3	17.893,3
Mantar	LDWPSO	1	9	60.010	%93,04	%92,73	%0,3	4	5	1,3	17.577,1
Mantar	LDWPSO	2	0	60.008	%93,87	%95,08	-1,2%	3	3	1	20.723,3
Mantar	LDWPSO	2	1	100.020	%96,20	%96,31	-0,1%	6	10	1,7	29.071,9
Mantar	LDWPSO	2	2	100.020	%96,20	%96,31	-0,1%	6	10	1,7	24.303,2
Mantar	LDWPSO	2	3	100.018	%95,61	%95,20	%0,4	5	8	1,6	25.390,4
Mantar	LDWPSO	2	4	100.020	%96,31	%76,85	%19,5	6	10	1,7	24.166,1
Mantar	LDWPSO	2	5	100.020	%96,21	%96,18	%0	6	10	1,7	24.119,8
Mantar	LDWPSO	2	6	100.020	%96,06	%97,54	-1,5%	6	10	1,7	22.604
Mantar	LDWPSO	2	7	100.020	%96,31	%95,32	%1	6	10	1,7	22.567,2
Mantar	LDWPSO	2	8	100.020	%96,23	%96,06	%0,2	6	10	1,7	20.990,8
Mantar	LDWPSO	2	9	100.020	%96,21	%96,18	%0	6	10	1,7	19.789,4
Mantar	LDWPSO	3	0	60.016	%95,45	%96,19	-0,7%	3	5	1,7	34.943,3
Mantar	LDWPSO	3	1	60.012	%93,63	%93,36	%0,3	4	6	1,5	19.435,1
Mantar	LDWPSO	3	2	60.012	%93,56	%93,97	-0,4%	4	6	1,5	19.497,2
Mantar	LDWPSO	3	3	60.012	%93,67	%92,99	%0,7	4	6	1,5	19.662,7
Mantar	LDWPSO	3	4	60.012	%93,56	%93,97	-0,4%	4	6	1,5	19.495,6
Mantar	LDWPSO	3	5	60.012	%93,65	%93,10	%0,6	4	6	1,5	19.706,5
Mantar	LDWPSO	3	6	60.012	%93,64	%93,23	%0,4	4	6	1,5	19.014,6
Mantar	LDWPSO	3	7	60.012	%93,56	%93,97	-0,4%	4	6	1,5	18.303,2
Mantar	LDWPSO	3	8	60.012	%93,57	%93,84	-0,3%	4	6	1,5	18.198,6
Mantar	LDWPSO	3	9	60.012	%93,64	%93,23	%0,4	4	6	1,5	17.789,9
Mantar	LDWPSO	4	0	60.019	%93,52	%94,34	-0,8%	4	6	1,5	18.519,3
Mantar	LDWPSO	4	1	60.019	%93,63	%93,36	%0,3	4	6	1,5	18.410,5
Mantar	LDWPSO	4	2	60.016	%93,56	%93,97	-0,4%	4	6	1,5	17.555,4
Mantar	LDWPSO	4	3	60.016	%93,67	%92,99	%0,7	4	6	1,5	16.957,1
Mantar	LDWPSO	4	4	60.015	%94,22	%93,97	%0,2	4	6	1,5	15.999
Mantar	LDWPSO	4	5	60.016	%93,65	%93,10	%0,6	4	6	1,5	15.310,8
Mantar	LDWPSO	4	6	60.016	%93,64	%93,23	%0,4	4	6	1,5	13.923,9
Mantar	LDWPSO	4	7	60.019	%93,56	%93,97	-0,4%	4	6	1,5	13.142,6
Mantar	LDWPSO	4	8	60.019	%93,57	%93,84	-0,3%	4	6	1,5	12.892,2
Mantar	LDWPSO	4	9	60.016	%93,64	%93,23	%0,4	4	6	1,5	12.702,1
Mantar	LDWPSO	5	0	60.012	%94,27	%93,48	%0,8	4	5	1,3	15.173
Mantar	LDWPSO	5	1	60.012	%94,19	%94,22	%0	4	5	1,3	15.162,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Mantar	LDWPSO	5	2	60.012	%94,09	%95,08	-1,0%	4	5	1,3	15.013,2
Mantar	LDWPSO	5	3	60.012	%94,17	%94,34	-0,2%	4	5	1,3	14.946,4
Mantar	LDWPSO	5	4	60.012	%94,17	%83,62	%10,6	4	5	1,3	13.691,2
Mantar	LDWPSO	5	5	60.012	%94,27	%93,47	%0,8	4	5	1,3	13.223,1
Mantar	LDWPSO	5	6	60.012	%94,15	%94,58	-0,4%	4	5	1,3	12.647,3
Mantar	LDWPSO	5	7	60.012	%94,11	%94,95	-0,8%	4	5	1,3	12.078,1
Mantar	LDWPSO	5	8	60.008	%94,23	%93,84	%0,4	4	4	1	10.991,9
Mantar	LDWPSO	5	9	60.012	%94,26	%93,60	%0,7	4	5	1,3	11.196
Mantar	PGIRLA	1	0	-	%98,40	%97,37	%1	20	238	11,9	21
Mantar	PGIRLA	1	1	-	%93,56	%93,80	-0,2%	20	218	10,9	21
Mantar	PGIRLA	1	2	-	%95,01	%95,96	-1,0%	20	203	10,2	20
Mantar	PGIRLA	1	3	-	%94,84	%95,41	-0,6%	20	210	10,5	21
Mantar	PGIRLA	1	4	-	%94,32	%94,46	-0,1%	20	219	11	20
Mantar	PGIRLA	1	5	-	%96,89	%96,77	%0,1	20	206	10,3	21
Mantar	PGIRLA	1	6	-	%96,75	%97,98	-1,2%	20	220	11	19
Mantar	PGIRLA	1	7	-	%98,96	%99,47	-0,5%	20	221	11,1	22
Mantar	PGIRLA	1	8	-	%99,31	%98,39	%0,9	20	205	10,3	19
Mantar	PGIRLA	1	9	-	%98,50	%98,59	-0,1%	20	201	10,1	20
Mantar	PGIRLA	2	0	-	%98,26	%97,94	%0,3	20	217	10,9	21
Mantar	PGIRLA	2	1	-	%97,21	%98,18	-1,0%	20	206	10,3	21
Mantar	PGIRLA	2	2	-	%99,43	%99,47	%0	20	200	10	20
Mantar	PGIRLA	2	3	-	%96,63	%96,65	%0	20	193	9,7	21
Mantar	PGIRLA	2	4	-	%98,48	%98,10	%0,4	20	211	10,6	20
Mantar	PGIRLA	2	5	-	%98,84	%99,10	-0,3%	20	209	10,5	21
Mantar	PGIRLA	2	6	-	%98,32	%99,50	-1,2%	20	180	9	19
Mantar	PGIRLA	2	7	-	%99,01	%98,95	%0,1	20	200	10	22
Mantar	PGIRLA	2	8	-	%96,62	%94,28	%2,3	20	228	11,4	19
Mantar	PGIRLA	2	9	-	%99,05	%98,59	%0,5	20	216	10,8	20
Mantar	PGIRLA	3	0	-	%98,26	%97,19	%1,1	20	206	10,3	21
Mantar	PGIRLA	3	1	-	%98,55	%98,91	-0,4%	20	223	11,2	21
Mantar	PGIRLA	3	2	-	%97,44	%97,89	-0,5%	20	197	9,9	20
Mantar	PGIRLA	3	3	-	%98,62	%98,24	%0,4	20	183	9,2	21
Mantar	PGIRLA	3	4	-	%98,48	%99,13	-0,7%	20	237	11,9	20
Mantar	PGIRLA	3	5	-	%98,25	%97,31	%0,9	20	221	11,1	21
Mantar	PGIRLA	3	6	-	%99,09	%98,32	%0,8	20	196	9,8	19
Mantar	PGIRLA	3	7	-	%98,32	%98,07	%0,3	20	217	10,9	22
Mantar	PGIRLA	3	8	-	%98,54	%97,50	%1	20	223	11,2	19
Mantar	PGIRLA	3	9	-	%98,98	%99,29	-0,3%	20	196	9,8	20
Mantar	PGIRLA	4	0	-	%98,22	%97,56	%0,7	20	201	10,1	21
Mantar	PGIRLA	4	1	-	%96,61	%95,80	%0,8	20	224	11,2	21
Mantar	PGIRLA	4	2	-	%96,95	%97,72	-0,8%	20	214	10,7	20
Mantar	PGIRLA	4	3	-	%98,72	%98,06	%0,7	20	215	10,8	21
Mantar	PGIRLA	4	4	-	%97,57	%97,75	-0,2%	20	221	11,1	20
Mantar	PGIRLA	4	5	-	%96,52	%97,31	-0,8%	20	245	12,3	21
Mantar	PGIRLA	4	6	-	%99,05	%99,33	-0,3%	20	194	9,7	19
Mantar	PGIRLA	4	7	-	%94,62	%94,56	%0,1	20	238	11,9	22
Mantar	PGIRLA	4	8	-	%94,32	%94,45	-0,1%	20	206	10,3	19
Mantar	PGIRLA	4	9	-	%96,61	%96,47	%0,1	20	203	10,2	20
Mantar	PGIRLA	5	0	-	%96,20	%95,87	%0,3	20	228	11,4	21
Mantar	PGIRLA	5	1	-	%94,98	%95,62	-0,6%	20	223	11,2	21
Mantar	PGIRLA	5	2	-	%97,08	%97,19	-0,1%	20	198	9,9	20
Mantar	PGIRLA	5	3	-	%98,38	%97,53	%0,9	20	221	11,1	21
Mantar	PGIRLA	5	4	-	%95,10	%95,16	-0,1%	20	214	10,7	20
Mantar	PGIRLA	5	5	-	%98,43	%98,57	-0,1%	20	204	10,2	21
Mantar	PGIRLA	5	6	-	%98,32	%98,82	-0,5%	20	234	11,7	19
Mantar	PGIRLA	5	7	-	%98,48	%98,07	%0,4	20	203	10,2	22
Mantar	PGIRLA	5	8	-	%97,13	%97,50	-0,4%	20	211	10,6	19
Mantar	PGIRLA	5	9	-	%95,12	%95,05	%0,1	20	234	11,7	20
Mantar	SIA	1	0	-	%100	%100	%0	26	90	3,5	2.078
Mantar	SIA	1	1	-	%100	%100	%0	23	102	4,4	2.057
Mantar	SIA	1	2	-	%100	%100	%0	29	74	2,6	2.403
Mantar	SIA	1	3	-	%100	%100	%0	18	88	4,9	1.639
Mantar	SIA	1	4	-	%100	%100	%0	26	65	2,5	2.160
Mantar	SIA	1	5	-	%99,89	%100	-0,1%	25	66	2,6	2.068
Mantar	SIA	1	6	-	%100	%100	%0	25	87	3,5	1.855
Mantar	SIA	1	7	-	%99,89	%100	-0,1%	25	81	3,2	2.024

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Mantar	SIA	1	8	-	%99,92	%99,75	%0,2	23	62	2,7	1.728
Mantar	SIA	1	9	-	%99,89	%100	-0,1%	21	66	3,1	1.776
Mantar	SIA	2	0	-	%99,88	%99,88	%0	28	102	3,6	2.055
Mantar	SIA	2	1	-	%100	%100	%0	27	46	1,7	2.218
Mantar	SIA	2	2	-	%99,90	%99,88	%0	17	68	4	1.257
Mantar	SIA	2	3	-	%100	%100	%0	26	80	3,1	2.230
Mantar	SIA	2	4	-	%99,90	%99,88	%0	25	80	3,2	2.122
Mantar	SIA	2	5	-	%100	%100	%0	32	72	2,3	2.864
Mantar	SIA	2	6	-	%100	%100	%0	21	84	4	1.609
Mantar	SIA	2	7	-	%100	%100	%0	36	71	2	2.443
Mantar	SIA	2	8	-	%99,92	%99,75	%0,2	28	70	2,5	2.304
Mantar	SIA	2	9	-	%100	%100	%0	32	73	2,3	2.365
Mantar	SIA	3	0	-	%99,90	%99,88	%0	26	84	3,2	2.133
Mantar	SIA	3	1	-	%100	%100	%0	23	86	3,7	1.924
Mantar	SIA	3	2	-	%100	%100	%0	22	83	3,8	1.666
Mantar	SIA	3	3	-	%100	%100	%0	21	90	4,3	1.616
Mantar	SIA	3	4	-	%100	%100	%0	22	68	3,1	1.587
Mantar	SIA	3	5	-	%99,84	%100	-0,2%	24	79	3,3	1.844
Mantar	SIA	3	6	-	%100	%100	%0	25	114	4,6	2.052
Mantar	SIA	3	7	-	%100	%100	%0	25	78	3,1	2.113
Mantar	SIA	3	8	-	%100	%100	%0	29	74	2,6	2.264
Mantar	SIA	3	9	-	%100	%100	%0	23	91	4	2.092
Mantar	SIA	4	0	-	%100	%100	%0	27	76	2,8	2.203
Mantar	SIA	4	1	-	%99,90	%99,88	%0	20	71	3,6	1.661
Mantar	SIA	4	2	-	%99,90	%99,88	%0	24	85	3,5	1.991
Mantar	SIA	4	3	-	%100	%100	%0	21	89	4,2	1.634
Mantar	SIA	4	4	-	%100	%100	%0	28	79	2,8	2.359
Mantar	SIA	4	5	-	%100	%100	%0	25	86	3,4	2.186
Mantar	SIA	4	6	-	%100	%100	%0	26	117	4,5	2.281
Mantar	SIA	4	7	-	%100	%100	%0	22	79	3,6	1.840
Mantar	SIA	4	8	-	%100	%100	%0	21	64	3	1.450
Mantar	SIA	4	9	-	%100	%100	%0	24	71	3	1.584
Mantar	SIA	5	0	-	%100	%100	%0	23	69	3	1.858
Mantar	SIA	5	1	-	%100	%100	%0	22	81	3,7	1.603
Mantar	SIA	5	2	-	%100	%100	%0	25	107	4,3	1.897
Mantar	SIA	5	3	-	%100	%100	%0	21	64	3	1.696
Mantar	SIA	5	4	-	%100	%100	%0	22	82	3,7	1.945
Mantar	SIA	5	5	-	%100	%100	%0	27	64	2,4	2.243
Mantar	SIA	5	6	-	%99,90	%99,88	%0	24	120	5	1.877
Mantar	SIA	5	7	-	%100	%100	%0	20	64	3,2	1.639
Mantar	SIA	5	8	-	%100	%100	%0	25	89	3,6	2.158
Mantar	SIA	5	9	-	%99,89	%100	-0,1%	26	78	3	2.345
Meme Kanseri	ABCMiner	1	0	100.755	%79,12	%71,43	%7,7	6	8	1,3	127,6
Meme Kanseri	ABCMiner	1	1	100.778	%78,31	%78,57	-0,3%	5	6	1,2	140,6
Meme Kanseri	ABCMiner	1	2	100.777	%74,70	%78,57	-3,9%	4	5	1,3	150,5
Meme Kanseri	ABCMiner	1	3	100.769	%75,90	%78,57	-2,7%	6	8	1,3	150,2
Meme Kanseri	ABCMiner	1	4	100.772	%79,52	%78,57	%0,9	6	9	1,5	157,7
Meme Kanseri	ABCMiner	1	5	100.778	%78,31	%75,00	%3,3	5	5	1	167,3
Meme Kanseri	ABCMiner	1	6	100.766	%77,51	%75,00	%2,5	4	4	1	160,4
Meme Kanseri	ABCMiner	1	7	80.616	%79,20	%70,37	%8,8	5	7	1,4	147,5
Meme Kanseri	ABCMiner	1	8	80.601	%76,40	%74,07	%2,3	5	6	1,2	146
Meme Kanseri	ABCMiner	1	9	100.760	%79,60	%66,67	%12,9	6	8	1,3	150,3
Meme Kanseri	ABCMiner	2	0	100.764	%79,12	%71,43	%7,7	6	8	1,3	122,4
Meme Kanseri	ABCMiner	2	1	100.751	%78,71	%75,00	%3,7	6	8	1,3	140,7
Meme Kanseri	ABCMiner	2	2	100.764	%75,50	%82,14	-6,6%	6	8	1,3	156,6
Meme Kanseri	ABCMiner	2	3	100.766	%75,50	%82,14	-6,6%	6	7	1,2	149,7
Meme Kanseri	ABCMiner	2	4	100.764	%79,12	%82,14	-3,0%	5	6	1,2	164,4
Meme Kanseri	ABCMiner	2	5	100.748	%78,31	%75,00	%3,3	6	8	1,3	163,9
Meme Kanseri	ABCMiner	2	6	100.768	%78,31	%78,57	-0,3%	6	8	1,3	157,2
Meme Kanseri	ABCMiner	2	7	80.611	%79,20	%70,37	%8,8	5	7	1,4	149,2
Meme Kanseri	ABCMiner	2	8	80.598	%76,40	%74,07	%2,3	5	6	1,2	142,4
Meme Kanseri	ABCMiner	2	9	100.749	%79,60	%66,67	%12,9	6	8	1,3	154,1
Meme Kanseri	ABCMiner	3	0	100.762	%79,12	%71,43	%7,7	6	8	1,3	125,9
Meme Kanseri	ABCMiner	3	1	100.771	%78,71	%75,00	%3,7	6	8	1,3	140,4
Meme Kanseri	ABCMiner	3	2	100.773	%74,70	%78,57	-3,9%	4	5	1,3	158,6
Meme Kanseri	ABCMiner	3	3	100.750	%75,90	%78,57	-2,7%	6	8	1,3	155,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Meme Kanseri	ABCMiner	3	4	100.780	%79,52	%78,57	%0,9	6	9	1,5	160,2
Meme Kanseri	ABCMiner	3	5	100.789	%77,91	%82,14	-4,2%	6	9	1,5	165,5
Meme Kanseri	ABCMiner	3	6	100.764	%78,31	%78,57	-0,3%	6	8	1,3	160,8
Meme Kanseri	ABCMiner	3	7	80.613	%79,20	%70,37	%8,8	5	7	1,4	151,5
Meme Kanseri	ABCMiner	3	8	80.603	%76,40	%74,07	%2,3	5	7	1,4	144,8
Meme Kanseri	ABCMiner	3	9	80.608	%78,80	%66,67	%12,1	5	5	1	149
Meme Kanseri	ABCMiner	4	0	80.612	%77,11	%67,86	%9,3	5	6	1,2	115,3
Meme Kanseri	ABCMiner	4	1	100.762	%78,71	%75,00	%3,7	6	8	1,3	122,1
Meme Kanseri	ABCMiner	4	2	100.776	%74,70	%78,57	-3,9%	4	5	1,3	120,9
Meme Kanseri	ABCMiner	4	3	100.767	%75,90	%78,57	-2,7%	6	8	1,3	121,9
Meme Kanseri	ABCMiner	4	4	100.761	%79,52	%78,57	%0,9	6	9	1,5	123,8
Meme Kanseri	ABCMiner	4	5	100.767	%77,91	%78,57	-0,7%	5	5	1	113,9
Meme Kanseri	ABCMiner	4	6	100.775	%77,51	%75,00	%2,5	4	4	1	117,7
Meme Kanseri	ABCMiner	4	7	80.611	%77,20	%66,67	%10,5	5	6	1,2	106,2
Meme Kanseri	ABCMiner	4	8	80.615	%76,40	%74,07	%2,3	5	7	1,4	111,1
Meme Kanseri	ABCMiner	4	9	100.757	%79,60	%66,67	%12,9	6	8	1,3	117,8
Meme Kanseri	ABCMiner	5	0	100.780	%79,12	%71,43	%7,7	6	8	1,3	123,8
Meme Kanseri	ABCMiner	5	1	100.763	%78,71	%82,14	-3,4%	5	6	1,2	130,4
Meme Kanseri	ABCMiner	5	2	100.762	%75,50	%82,14	-6,6%	6	7	1,2	114,4
Meme Kanseri	ABCMiner	5	3	100.772	%75,50	%82,14	-6,6%	6	7	1,2	119,8
Meme Kanseri	ABCMiner	5	4	100.776	%79,52	%78,57	%0,9	6	9	1,5	124,7
Meme Kanseri	ABCMiner	5	5	100.746	%78,31	%75,00	%3,3	6	8	1,3	123,2
Meme Kanseri	ABCMiner	5	6	100.770	%78,31	%78,57	-0,3%	6	8	1,3	121,5
Meme Kanseri	ABCMiner	5	7	80.597	%77,20	%66,67	%10,5	5	6	1,2	109,6
Meme Kanseri	ABCMiner	5	8	80.614	%76,40	%74,07	%2,3	5	7	1,4	107,7
Meme Kanseri	ABCMiner	5	9	100.754	%79,60	%66,67	%12,9	6	8	1,3	120
Meme Kanseri	C4.5	-	1	-	%74,30	%78,57	-4,3%	10	35	3,5	0,4
Meme Kanseri	C4.5	-	2	-	%71,89	%78,57	-6,7%	13	41	3,2	0,4
Meme Kanseri	C4.5	-	3	-	%75,50	%82,14	-6,6%	13	36	2,8	0,4
Meme Kanseri	C4.5	-	4	-	%75,90	%75,00	%0,9	18	64	3,6	0,4
Meme Kanseri	C4.5	-	5	-	%75,90	%67,86	%8	14	47	3,4	0,4
Meme Kanseri	C4.5	-	6	-	%74,70	%60,71	%14	12	35	2,9	0,4
Meme Kanseri	C4.5	-	7	-	%73,90	%75,00	-1,1%	13	48	3,7	0,4
Meme Kanseri	C4.5	-	8	-	%75,20	%66,67	%8,5	9	26	2,9	0,4
Meme Kanseri	C4.5	-	9	-	%73,60	%66,67	%6,9	13	45	3,5	0,4
Meme Kanseri	C4.5	-	10	-	%74,80	%62,96	%11,8	10	31	3,1	0,4
Meme Kanseri	CoABCMiner	1	0	110.624	%82,33	%75,00	%7,3	15	53	3,5	2
Meme Kanseri	CoABCMiner	1	1	110.621	%80,72	%75,00	%5,7	18	57	3,2	1,8
Meme Kanseri	CoABCMiner	1	2	110.614	%81,12	%82,14	-1,0%	17	69	4,1	2,2
Meme Kanseri	CoABCMiner	1	3	110.626	%81,12	%78,57	%2,6	19	62	3,3	1,8
Meme Kanseri	CoABCMiner	1	4	110.603	%79,92	%82,14	-2,2%	19	65	3,4	2
Meme Kanseri	CoABCMiner	1	5	110.624	%81,12	%75,00	%6,1	21	79	3,8	1,8
Meme Kanseri	CoABCMiner	1	6	110.643	%81,53	%75,00	%6,5	18	65	3,6	2
Meme Kanseri	CoABCMiner	1	7	110.606	%82,00	%70,37	%11,6	18	65	3,6	2
Meme Kanseri	CoABCMiner	1	8	110.580	%80,00	%85,19	-5,2%	20	65	3,3	1,9
Meme Kanseri	CoABCMiner	1	9	110.618	%82,80	%66,67	%16,1	17	64	3,8	2
Meme Kanseri	CoABCMiner	2	0	110.643	%81,93	%71,43	%10,5	16	51	3,2	2
Meme Kanseri	CoABCMiner	2	1	110.600	%81,12	%78,57	%2,6	21	70	3,3	2
Meme Kanseri	CoABCMiner	2	2	110.626	%81,53	%82,14	-0,6%	17	58	3,4	2,2
Meme Kanseri	CoABCMiner	2	3	110.636	%80,32	%82,14	-1,8%	20	70	3,5	1,8
Meme Kanseri	CoABCMiner	2	4	110.601	%81,12	%67,86	%13,3	17	58	3,4	2,1
Meme Kanseri	CoABCMiner	2	5	110.627	%81,12	%78,57	%2,6	20	67	3,4	2,1
Meme Kanseri	CoABCMiner	2	6	110.634	%80,72	%71,43	%9,3	19	67	3,5	2
Meme Kanseri	CoABCMiner	2	7	110.608	%82,00	%74,07	%7,9	18	61	3,4	2,1
Meme Kanseri	CoABCMiner	2	8	110.623	%80,40	%85,19	-4,8%	21	75	3,6	1,9
Meme Kanseri	CoABCMiner	2	9	110.636	%82,40	%62,96	%19,4	18	56	3,1	1,9
Meme Kanseri	CoABCMiner	3	0	110.613	%80,72	%71,43	%9,3	15	43	2,9	2
Meme Kanseri	CoABCMiner	3	1	110.591	%81,12	%75,00	%6,1	18	62	3,4	2,1
Meme Kanseri	CoABCMiner	3	2	110.602	%81,53	%85,71	-4,2%	20	69	3,5	2
Meme Kanseri	CoABCMiner	3	3	110.623	%81,53	%82,14	-0,6%	22	86	3,9	1,9
Meme Kanseri	CoABCMiner	3	4	110.601	%81,12	%71,43	%9,7	23	79	3,4	2,1
Meme Kanseri	CoABCMiner	3	5	110.617	%82,33	%75,00	%7,3	17	72	4,2	2,1
Meme Kanseri	CoABCMiner	3	6	110.640	%81,53	%78,57	%3	17	57	3,4	2,2
Meme Kanseri	CoABCMiner	3	7	110.614	%82,00	%74,07	%7,9	18	69	3,8	2,1
Meme Kanseri	CoABCMiner	3	8	110.621	%80,40	%88,89	-8,5%	18	50	2,8	2,1
Meme Kanseri	CoABCMiner	3	9	110.626	%82,40	%62,96	%19,4	16	58	3,6	2,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Meme Kanseri	CoABCMiner	4	0	110.607	%81,12	%71,43	%9,7	16	53	3,3	2
Meme Kanseri	CoABCMiner	4	1	110.621	%80,72	%75,00	%5,7	17	60	3,5	2
Meme Kanseri	CoABCMiner	4	2	110.589	%81,53	%85,71	-4,2%	16	71	4,4	2,2
Meme Kanseri	CoABCMiner	4	3	110.614	%81,12	%78,57	%2,6	22	67	3	1,8
Meme Kanseri	CoABCMiner	4	4	110.596	%79,52	%78,57	%0,9	14	49	3,5	2
Meme Kanseri	CoABCMiner	4	5	110.629	%81,12	%71,43	%9,7	12	47	3,9	2,1
Meme Kanseri	CoABCMiner	4	6	110.663	%81,12	%71,43	%9,7	16	42	2,6	1,9
Meme Kanseri	CoABCMiner	4	7	110.625	%81,60	%70,37	%11,2	19	71	3,7	2,1
Meme Kanseri	CoABCMiner	4	8	110.610	%80,40	%81,48	-1,1%	22	81	3,7	1,9
Meme Kanseri	CoABCMiner	4	9	110.631	%82,80	%62,96	%19,8	20	74	3,7	2
Meme Kanseri	CoABCMiner	5	0	110.600	%82,33	%71,43	%10,9	19	62	3,3	1,9
Meme Kanseri	CoABCMiner	5	1	110.624	%81,12	%75,00	%6,1	20	70	3,5	2,1
Meme Kanseri	CoABCMiner	5	2	110.588	%81,93	%82,14	-0,2%	17	71	4,2	2
Meme Kanseri	CoABCMiner	5	3	110.640	%81,12	%82,14	-1,0%	20	68	3,4	1,9
Meme Kanseri	CoABCMiner	5	4	110.624	%79,92	%89,29	-9,4%	14	47	3,4	2
Meme Kanseri	CoABCMiner	5	5	110.622	%81,12	%75,00	%6,1	20	77	3,9	2
Meme Kanseri	CoABCMiner	5	6	110.626	%81,93	%71,43	%10,5	18	66	3,7	2,1
Meme Kanseri	CoABCMiner	5	7	110.597	%82,00	%70,37	%11,6	17	62	3,6	1,9
Meme Kanseri	CoABCMiner	5	8	110.609	%80,00	%81,48	-1,5%	22	53	2,4	2,1
Meme Kanseri	CoABCMiner	5	9	110.602	%82,80	%62,96	%19,8	19	71	3,7	2
Meme Kanseri	CORE	1	0	1.964.964	%80,72	%75,00	%5,7	5	12	2,4	32,1
Meme Kanseri	CORE	1	1	1.965.648	%80,32	%75,00	%5,3	6	13	2,2	31,7
Meme Kanseri	CORE	1	2	1.965.335	%80,72	%78,57	%2,2	11	32	2,9	32,3
Meme Kanseri	CORE	1	3	1.965.035	%80,72	%78,57	%2,2	11	29	2,6	33,7
Meme Kanseri	CORE	1	4	1.966.568	%79,92	%82,14	-2,2%	5	12	2,4	31,9
Meme Kanseri	CORE	1	5	1.964.997	%80,32	%75,00	%5,3	7	15	2,1	32,8
Meme Kanseri	CORE	1	6	1.966.428	%80,32	%71,43	%8,9	5	10	2	33,3
Meme Kanseri	CORE	1	7	1.965.768	%81,60	%70,37	%11,2	12	40	3,3	32,4
Meme Kanseri	CORE	1	8	1.964.281	%80,00	%74,07	%5,9	9	19	2,1	31,4
Meme Kanseri	CORE	1	9	1.966.972	%81,20	%55,56	%25,6	9	17	1,9	33
Meme Kanseri	CORE	2	0	-	%80,72	%67,86	%12,9	9	15	1,7	31,3
Meme Kanseri	CORE	2	1	-	%79,92	%67,86	%12,1	5	14	2,8	31,8
Meme Kanseri	CORE	2	2	-	%79,92	%78,57	%1,3	9	18	2	33,1
Meme Kanseri	CORE	2	3	-	%80,72	%78,57	%2,2	11	28	2,5	32,7
Meme Kanseri	CORE	2	4	-	%79,92	%71,43	%8,5	6	12	2	32,2
Meme Kanseri	CORE	2	5	-	%81,12	%71,43	%9,7	8	18	2,3	32,3
Meme Kanseri	CORE	2	6	-	%80,32	%75,00	%5,3	5	13	2,6	33
Meme Kanseri	CORE	2	7	-	%82,00	%70,37	%11,6	12	28	2,3	32,4
Meme Kanseri	CORE	2	8	-	%80,40	%74,07	%6,3	11	26	2,4	33,7
Meme Kanseri	CORE	2	9	-	%81,20	%70,37	%10,8	5	17	3,4	33,3
Meme Kanseri	CORE	3	0	-	%81,53	%71,43	%10,1	7	19	2,7	33,6
Meme Kanseri	CORE	3	1	-	%79,52	%67,86	%11,7	5	13	2,6	31,9
Meme Kanseri	CORE	3	2	-	%79,52	%78,57	%0,9	6	15	2,5	33,3
Meme Kanseri	CORE	3	3	-	%79,92	%78,57	%1,3	9	21	2,3	31
Meme Kanseri	CORE	3	4	-	%79,92	%78,57	%1,3	8	22	2,8	32,6
Meme Kanseri	CORE	3	5	-	%79,92	%78,57	%1,3	7	11	1,6	30,9
Meme Kanseri	CORE	3	6	-	%80,32	%78,57	%1,7	8	22	2,8	34,3
Meme Kanseri	CORE	3	7	-	%80,80	%74,07	%6,7	7	14	2	31,6
Meme Kanseri	CORE	3	8	-	%80,40	%74,07	%6,3	8	19	2,4	32,5
Meme Kanseri	CORE	3	9	-	%80,80	%66,67	%14,1	7	17	2,4	31,7
Meme Kanseri	CORE	4	0	-	%81,12	%71,43	%9,7	12	28	2,3	32,8
Meme Kanseri	CORE	4	1	-	%80,72	%67,86	%12,9	7	18	2,6	29,8
Meme Kanseri	CORE	4	2	-	%80,32	%78,57	%1,7	9	22	2,4	32,1
Meme Kanseri	CORE	4	3	-	%79,52	%82,14	-2,6%	5	9	1,8	31,4
Meme Kanseri	CORE	4	4	-	%79,92	%60,71	%19,2	12	28	2,3	32,8
Meme Kanseri	CORE	4	5	-	%80,72	%82,14	-1,4%	14	28	2	33,9
Meme Kanseri	CORE	4	6	-	%80,72	%78,57	%2,2	10	25	2,5	34,9
Meme Kanseri	CORE	4	7	-	%82,00	%66,67	%15,3	12	30	2,5	32,8
Meme Kanseri	CORE	4	8	-	%80,40	%74,07	%6,3	6	14	2,3	31
Meme Kanseri	CORE	4	9	-	%81,20	%66,67	%14,5	4	13	3,3	32,3
Meme Kanseri	CORE	5	0	-	%81,12	%78,57	%2,6	8	16	2	31,5
Meme Kanseri	CORE	5	1	-	%80,32	%78,57	%1,7	7	15	2,1	32,1
Meme Kanseri	CORE	5	2	-	%80,32	%85,71	-5,4%	12	35	2,9	33,6
Meme Kanseri	CORE	5	3	-	%79,52	%78,57	%0,9	5	11	2,2	31,7
Meme Kanseri	CORE	5	4	-	%79,92	%75,00	%4,9	13	25	1,9	32,7
Meme Kanseri	CORE	5	5	-	%80,72	%67,86	%12,9	8	20	2,5	32,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Meme Kanseri	CORE	5	6	-	%81,12	%71,43	%9,7	8	17	2,1	33,8
Meme Kanseri	CORE	5	7	-	%80,80	%70,37	%10,4	9	22	2,4	32,3
Meme Kanseri	CORE	5	8	-	%80,00	%74,07	%5,9	8	17	2,1	32,8
Meme Kanseri	CORE	5	9	-	%81,20	%62,96	%18,2	6	12	2	33,8
Meme Kanseri	HIDER	1	0	-	%78,30	%71,40	%6,9	3	10	3,3	4
Meme Kanseri	HIDER	1	1	-	%75,90	%75,00	%0,9	3	10	3,3	3
Meme Kanseri	HIDER	1	2	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	1	3	-	%72,70	%71,40	%1,3	2	8	4	2
Meme Kanseri	HIDER	1	4	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	1	5	-	%73,10	%67,90	%5,2	2	8	4	3
Meme Kanseri	HIDER	1	6	-	%77,50	%78,60	-1,1%	3	10	3,3	3
Meme Kanseri	HIDER	1	7	-	%74,00	%59,30	%14,7	2	8	4	3
Meme Kanseri	HIDER	1	8	-	%77,20	%81,50	-4,3%	3	10	3,3	3
Meme Kanseri	HIDER	1	9	-	%77,20	%70,40	%6,8	3	11	3,7	3
Meme Kanseri	HIDER	2	0	-	%78,30	%71,40	%6,9	3	10	3,3	4
Meme Kanseri	HIDER	2	1	-	%75,90	%75,00	%0,9	3	10	3,3	3
Meme Kanseri	HIDER	2	2	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	2	3	-	%72,70	%71,40	%1,3	2	8	4	2
Meme Kanseri	HIDER	2	4	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	2	5	-	%73,10	%67,90	%5,2	2	8	4	3
Meme Kanseri	HIDER	2	6	-	%77,50	%78,60	-1,1%	3	10	3,3	3
Meme Kanseri	HIDER	2	7	-	%74,00	%59,30	%14,7	2	8	4	3
Meme Kanseri	HIDER	2	8	-	%77,20	%81,50	-4,3%	3	10	3,3	3
Meme Kanseri	HIDER	2	9	-	%77,20	%70,40	%6,8	3	11	3,7	3
Meme Kanseri	HIDER	3	0	-	%78,30	%71,40	%6,9	3	10	3,3	4
Meme Kanseri	HIDER	3	1	-	%75,90	%75,00	%0,9	3	10	3,3	3
Meme Kanseri	HIDER	3	2	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	3	3	-	%72,70	%71,40	%1,3	2	8	4	2
Meme Kanseri	HIDER	3	4	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	3	5	-	%73,10	%67,90	%5,2	2	8	4	3
Meme Kanseri	HIDER	3	6	-	%77,50	%78,60	-1,1%	3	10	3,3	3
Meme Kanseri	HIDER	3	7	-	%74,00	%59,30	%14,7	2	8	4	3
Meme Kanseri	HIDER	3	8	-	%77,20	%81,50	-4,3%	3	10	3,3	3
Meme Kanseri	HIDER	3	9	-	%77,20	%70,40	%6,8	3	11	3,7	3
Meme Kanseri	HIDER	4	0	-	%78,30	%71,40	%6,9	3	10	3,3	4
Meme Kanseri	HIDER	4	1	-	%75,90	%75,00	%0,9	3	10	3,3	3
Meme Kanseri	HIDER	4	2	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	4	3	-	%72,70	%71,40	%1,3	2	8	4	2
Meme Kanseri	HIDER	4	4	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	4	5	-	%73,10	%67,90	%5,2	2	8	4	3
Meme Kanseri	HIDER	4	6	-	%77,50	%78,60	-1,1%	3	10	3,3	3
Meme Kanseri	HIDER	4	7	-	%74,00	%59,30	%14,7	2	8	4	3
Meme Kanseri	HIDER	4	8	-	%77,20	%81,50	-4,3%	3	10	3,3	3
Meme Kanseri	HIDER	4	9	-	%77,20	%70,40	%6,8	3	11	3,7	3
Meme Kanseri	HIDER	5	0	-	%78,30	%71,40	%6,9	3	10	3,3	4
Meme Kanseri	HIDER	5	1	-	%75,90	%75,00	%0,9	3	10	3,3	3
Meme Kanseri	HIDER	5	2	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	5	3	-	%72,70	%71,40	%1,3	2	8	4	2
Meme Kanseri	HIDER	5	4	-	%76,70	%85,70	-9,0%	3	10	3,3	4
Meme Kanseri	HIDER	5	5	-	%73,10	%67,90	%5,2	2	8	4	3
Meme Kanseri	HIDER	5	6	-	%77,50	%78,60	-1,1%	3	10	3,3	3
Meme Kanseri	HIDER	5	7	-	%74,00	%59,30	%14,7	2	8	4	3
Meme Kanseri	HIDER	5	8	-	%77,20	%81,50	-4,3%	3	10	3,3	3
Meme Kanseri	HIDER	5	9	-	%77,20	%70,40	%6,8	3	11	3,7	3
Meme Kanseri	LDWPSO	1	0	80.014	%78,31	%67,86	%10,5	5	6	1,2	190,3
Meme Kanseri	LDWPSO	1	1	100.018	%78,71	%75,00	%3,7	6	8	1,3	212,5
Meme Kanseri	LDWPSO	1	2	100.014	%77,51	%82,14	-4,6%	5	5	1	187,7
Meme Kanseri	LDWPSO	1	3	80.010	%77,51	%78,57	-1,1%	5	5	1	173,7
Meme Kanseri	LDWPSO	1	4	100.020	%76,71	%71,43	%5,3	6	9	1,5	197
Meme Kanseri	LDWPSO	1	5	80.012	%75,90	%82,14	-6,2%	5	6	1,2	193,2
Meme Kanseri	LDWPSO	1	6	80.012	%75,50	%75,00	%0,5	5	6	1,2	170,6
Meme Kanseri	LDWPSO	1	7	80.016	%79,20	%70,37	%8,8	5	7	1,4	183
Meme Kanseri	LDWPSO	1	8	80.010	%76,40	%77,78	-1,4%	5	5	1	167,9
Meme Kanseri	LDWPSO	1	9	80.012	%78,40	%70,37	%8	3	3	1	172,7
Meme Kanseri	LDWPSO	2	0	100.018	%79,12	%71,43	%7,7	6	8	1,3	208,4
Meme Kanseri	LDWPSO	2	1	100.018	%78,71	%75,00	%3,7	6	8	1,3	211,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Meme Kanseri	LDWPSO	2	2	100.018	%74,70	%78,57	-3,9%	4	5	1,3	210,3
Meme Kanseri	LDWPSO	2	3	100.018	%75,90	%78,57	-2,7%	6	8	1,3	212,4
Meme Kanseri	LDWPSO	2	4	100.020	%79,52	%78,57	%0,9	6	9	1,5	198,6
Meme Kanseri	LDWPSO	2	5	100.014	%77,91	%78,57	-0,7%	5	5	1	213
Meme Kanseri	LDWPSO	2	6	100.014	%78,31	%75,00	%3,3	5	5	1	222,4
Meme Kanseri	LDWPSO	2	7	80.016	%79,20	%70,37	%8,8	5	7	1,4	193,6
Meme Kanseri	LDWPSO	2	8	80.016	%76,40	%74,07	%2,3	5	7	1,4	201,2
Meme Kanseri	LDWPSO	2	9	100.018	%79,60	%66,67	%12,9	6	8	1,3	206,3
Meme Kanseri	LDWPSO	3	0	80.016	%76,71	%71,43	%5,3	5	7	1,4	193,3
Meme Kanseri	LDWPSO	3	1	120.026	%80,32	%75,00	%5,3	6	10	1,7	211,7
Meme Kanseri	LDWPSO	3	2	100.018	%74,70	%78,57	-3,9%	4	5	1,3	203,4
Meme Kanseri	LDWPSO	3	3	100.018	%75,90	%78,57	-2,7%	6	8	1,3	205,1
Meme Kanseri	LDWPSO	3	4	100.020	%79,52	%78,57	%0,9	6	9	1,5	208,4
Meme Kanseri	LDWPSO	3	5	100.018	%77,11	%78,57	-1,5%	6	8	1,3	206,3
Meme Kanseri	LDWPSO	3	6	100.018	%77,51	%75,00	%2,5	5	7	1,4	209,1
Meme Kanseri	LDWPSO	3	7	80.016	%77,20	%66,67	%10,5	5	7	1,4	192,5
Meme Kanseri	LDWPSO	3	8	80.016	%76,40	%74,07	%2,3	5	7	1,4	200,3
Meme Kanseri	LDWPSO	3	9	80.016	%76,80	%70,37	%6,4	5	7	1,4	192,2
Meme Kanseri	LDWPSO	4	0	100.014	%77,11	%67,86	%9,3	6	7	1,2	202,5
Meme Kanseri	LDWPSO	4	1	100.014	%76,71	%82,14	-5,4%	5	5	1	195,5
Meme Kanseri	LDWPSO	4	2	100.018	%75,50	%82,14	-6,6%	6	8	1,3	213,2
Meme Kanseri	LDWPSO	4	3	100.018	%75,90	%78,57	-2,7%	6	8	1,3	210,7
Meme Kanseri	LDWPSO	4	4	100.014	%77,11	%78,57	-1,5%	4	4	1	196,8
Meme Kanseri	LDWPSO	4	5	100.018	%77,91	%82,14	-4,2%	6	8	1,3	199,6
Meme Kanseri	LDWPSO	4	6	100.018	%78,31	%78,57	-0,3%	6	8	1,3	201,7
Meme Kanseri	LDWPSO	4	7	80.012	%77,20	%66,67	%10,5	5	6	1,2	187,4
Meme Kanseri	LDWPSO	4	8	100.018	%76,40	%74,07	%2,3	6	8	1,3	207,1
Meme Kanseri	LDWPSO	4	9	100.018	%79,60	%66,67	%12,9	6	8	1,3	198,4
Meme Kanseri	LDWPSO	5	0	80.016	%79,52	%75,00	%4,5	5	7	1,4	211
Meme Kanseri	LDWPSO	5	1	100.016	%77,91	%71,43	%6,5	5	5	1	216,1
Meme Kanseri	LDWPSO	5	2	80.012	%75,90	%82,14	-6,2%	5	6	1,2	203,1
Meme Kanseri	LDWPSO	5	3	100.018	%75,90	%78,57	-2,7%	6	8	1,3	218,8
Meme Kanseri	LDWPSO	5	4	100.020	%79,92	%82,14	-2,2%	6	9	1,5	224,2
Meme Kanseri	LDWPSO	5	5	80.020	%77,91	%85,71	-7,8%	5	6	1,2	208,3
Meme Kanseri	LDWPSO	5	6	100.020	%78,71	%71,43	%7,3	5	7	1,4	218,4
Meme Kanseri	LDWPSO	5	7	80.016	%80,00	%70,37	%9,6	5	7	1,4	219
Meme Kanseri	LDWPSO	5	8	100.014	%76,40	%77,78	-1,4%	6	7	1,2	215,3
Meme Kanseri	LDWPSO	5	9	100.016	%78,40	%66,67	%11,7	6	7	1,2	209,2
Meme Kanseri	PGIRLA	1	0	-	%80,72	%67,86	%12,9	20	85	4,3	1
Meme Kanseri	PGIRLA	1	1	-	%79,52	%75,00	%4,5	20	83	4,2	2
Meme Kanseri	PGIRLA	1	2	-	%79,92	%82,14	-2,2%	20	78	3,9	1
Meme Kanseri	PGIRLA	1	3	-	%79,52	%75,00	%4,5	20	74	3,7	1
Meme Kanseri	PGIRLA	1	4	-	%80,32	%64,29	%16	20	71	3,6	2
Meme Kanseri	PGIRLA	1	5	-	%83,13	%78,57	%4,6	20	81	4,1	1
Meme Kanseri	PGIRLA	1	6	-	%81,53	%71,43	%10,1	20	81	4,1	2
Meme Kanseri	PGIRLA	1	7	-	%81,20	%66,67	%14,5	20	81	4,1	1
Meme Kanseri	PGIRLA	1	8	-	%81,20	%74,07	%7,1	20	73	3,7	2
Meme Kanseri	PGIRLA	1	9	-	%80,80	%70,37	%10,4	20	80	4	1
Meme Kanseri	PGIRLA	2	0	-	%81,53	%71,43	%10,1	20	68	3,4	1
Meme Kanseri	PGIRLA	2	1	-	%79,92	%67,86	%12,1	20	78	3,9	2
Meme Kanseri	PGIRLA	2	2	-	%80,32	%85,71	-5,4%	20	79	4	1
Meme Kanseri	PGIRLA	2	3	-	%80,32	%75,00	%5,3	20	73	3,7	1
Meme Kanseri	PGIRLA	2	4	-	%80,72	%75,00	%5,7	20	70	3,5	2
Meme Kanseri	PGIRLA	2	5	-	%79,92	%64,29	%15,6	20	67	3,4	1
Meme Kanseri	PGIRLA	2	6	-	%79,52	%71,43	%8,1	20	67	3,4	2
Meme Kanseri	PGIRLA	2	7	-	%81,20	%66,67	%14,5	20	72	3,6	1
Meme Kanseri	PGIRLA	2	8	-	%80,80	%77,78	%3	20	70	3,5	2
Meme Kanseri	PGIRLA	2	9	-	%81,60	%66,67	%14,9	20	68	3,4	1
Meme Kanseri	PGIRLA	3	0	-	%81,12	%67,86	%13,3	20	72	3,6	1
Meme Kanseri	PGIRLA	3	1	-	%81,12	%71,43	%9,7	20	75	3,8	2
Meme Kanseri	PGIRLA	3	2	-	%80,32	%85,71	-5,4%	20	80	4	1
Meme Kanseri	PGIRLA	3	3	-	%79,52	%71,43	%8,1	20	80	4	1
Meme Kanseri	PGIRLA	3	4	-	%79,92	%78,57	%1,3	20	74	3,7	2
Meme Kanseri	PGIRLA	3	5	-	%81,53	%64,29	%17,2	20	80	4	1
Meme Kanseri	PGIRLA	3	6	-	%80,72	%71,43	%9,3	20	80	4	2
Meme Kanseri	PGIRLA	3	7	-	%80,40	%66,67	%13,7	20	78	3,9	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Meme Kanseri	PGIRLA	3	8	-	%79,20	%81,48	-2,3%	20	69	3,5	2
Meme Kanseri	PGIRLA	3	9	-	%80,80	%59,26	%21,5	20	83	4,2	1
Meme Kanseri	PGIRLA	4	0	-	%81,93	%67,86	%14,1	20	82	4,1	1
Meme Kanseri	PGIRLA	4	1	-	%79,92	%75,00	%4,9	20	83	4,2	2
Meme Kanseri	PGIRLA	4	2	-	%79,92	%82,14	-2,2%	20	77	3,9	1
Meme Kanseri	PGIRLA	4	3	-	%80,32	%78,57	%1,7	20	77	3,9	1
Meme Kanseri	PGIRLA	4	4	-	%79,52	%71,43	%8,1	20	79	4	2
Meme Kanseri	PGIRLA	4	5	-	%80,32	%71,43	%8,9	20	68	3,4	1
Meme Kanseri	PGIRLA	4	6	-	%79,92	%71,43	%8,5	20	67	3,4	2
Meme Kanseri	PGIRLA	4	7	-	%80,40	%48,15	%32,3	20	72	3,6	1
Meme Kanseri	PGIRLA	4	8	-	%80,00	%77,78	%2,2	20	90	4,5	2
Meme Kanseri	PGIRLA	4	9	-	%81,20	%66,67	%14,5	20	81	4,1	1
Meme Kanseri	PGIRLA	5	0	-	%81,12	%71,43	%9,7	20	80	4	1
Meme Kanseri	PGIRLA	5	1	-	%81,93	%67,86	%14,1	20	81	4,1	2
Meme Kanseri	PGIRLA	5	2	-	%79,52	%82,14	-2,6%	20	84	4,2	1
Meme Kanseri	PGIRLA	5	3	-	%81,12	%82,14	-1,0%	20	76	3,8	1
Meme Kanseri	PGIRLA	5	4	-	%79,92	%82,14	-2,2%	20	85	4,3	2
Meme Kanseri	PGIRLA	5	5	-	%81,12	%67,86	%13,3	20	75	3,8	1
Meme Kanseri	PGIRLA	5	6	-	%80,32	%75,00	%5,3	20	83	4,2	2
Meme Kanseri	PGIRLA	5	7	-	%82,40	%70,37	%12	20	89	4,5	1
Meme Kanseri	PGIRLA	5	8	-	%80,00	%77,78	%2,2	20	76	3,8	2
Meme Kanseri	PGIRLA	5	9	-	%80,80	%62,96	%17,8	20	81	4,1	1
Meme Kanseri	SIA	1	0	-	%97,19	%60,71	%36,5	86	350	4,1	3
Meme Kanseri	SIA	1	1	-	%98,39	%67,86	%30,5	88	357	4,1	4
Meme Kanseri	SIA	1	2	-	%96,39	%78,57	%17,8	89	351	3,9	4
Meme Kanseri	SIA	1	3	-	%97,59	%78,57	%19	95	352	3,7	4
Meme Kanseri	SIA	1	4	-	%97,59	%71,43	%26,2	88	358	4,1	4
Meme Kanseri	SIA	1	5	-	%96,39	%71,43	%25	90	362	4	4
Meme Kanseri	SIA	1	6	-	%97,59	%75,00	%22,6	94	385	4,1	4
Meme Kanseri	SIA	1	7	-	%97,20	%74,07	%23,1	91	370	4,1	4
Meme Kanseri	SIA	1	8	-	%97,60	%70,37	%27,2	86	397	4,6	3
Meme Kanseri	SIA	1	9	-	%97,60	%59,26	%38,3	79	404	5,1	3
Meme Kanseri	SIA	2	0	-	%97,19	%67,86	%29,3	88	376	4,3	3
Meme Kanseri	SIA	2	1	-	%98,80	%53,57	%45,2	89	371	4,2	4
Meme Kanseri	SIA	2	2	-	%96,79	%78,57	%18,2	91	323	3,5	4
Meme Kanseri	SIA	2	3	-	%97,19	%78,57	%18,6	87	342	3,9	3
Meme Kanseri	SIA	2	4	-	%97,59	%71,43	%26,2	85	351	4,1	3
Meme Kanseri	SIA	2	5	-	%96,39	%50,00	%46,4	85	376	4,4	3
Meme Kanseri	SIA	2	6	-	%96,79	%71,43	%25,4	93	364	3,9	4
Meme Kanseri	SIA	2	7	-	%97,60	%70,37	%27,2	86	381	4,4	3
Meme Kanseri	SIA	2	8	-	%98,40	%74,07	%24,3	91	341	3,7	4
Meme Kanseri	SIA	2	9	-	%97,20	%70,37	%26,8	83	344	4,1	3
Meme Kanseri	SIA	3	0	-	%97,19	%64,29	%32,9	87	363	4,2	3
Meme Kanseri	SIA	3	1	-	%98,80	%64,29	%34,5	93	363	3,9	4
Meme Kanseri	SIA	3	2	-	%97,19	%78,57	%18,6	82	395	4,8	3
Meme Kanseri	SIA	3	3	-	%96,79	%78,57	%18,2	92	357	3,9	4
Meme Kanseri	SIA	3	4	-	%97,59	%75,00	%22,6	97	377	3,9	4
Meme Kanseri	SIA	3	5	-	%96,79	%53,57	%43,2	91	362	4	4
Meme Kanseri	SIA	3	6	-	%97,19	%71,43	%25,8	82	344	4,2	3
Meme Kanseri	SIA	3	7	-	%96,80	%66,67	%30,1	90	372	4,1	3
Meme Kanseri	SIA	3	8	-	%98,00	%70,37	%27,6	92	318	3,5	4
Meme Kanseri	SIA	3	9	-	%97,20	%66,67	%30,5	82	366	4,5	4
Meme Kanseri	SIA	4	0	-	%97,19	%67,86	%29,3	88	389	4,4	3
Meme Kanseri	SIA	4	1	-	%98,80	%60,71	%38,1	93	400	4,3	4
Meme Kanseri	SIA	4	2	-	%96,79	%78,57	%18,2	85	356	4,2	3
Meme Kanseri	SIA	4	3	-	%96,79	%75,00	%21,8	85	398	4,7	4
Meme Kanseri	SIA	4	4	-	%97,59	%75,00	%22,6	86	375	4,4	3
Meme Kanseri	SIA	4	5	-	%95,58	%67,86	%27,7	78	369	4,7	3
Meme Kanseri	SIA	4	6	-	%97,59	%82,14	%15,4	94	347	3,7	4
Meme Kanseri	SIA	4	7	-	%98,00	%74,07	%23,9	92	368	4	3
Meme Kanseri	SIA	4	8	-	%98,40	%66,67	%31,7	95	388	4,1	4
Meme Kanseri	SIA	4	9	-	%96,80	%62,96	%33,8	85	375	4,4	3
Meme Kanseri	SIA	5	0	-	%97,19	%71,43	%25,8	88	362	4,1	4
Meme Kanseri	SIA	5	1	-	%98,80	%67,86	%30,9	93	372	4	4
Meme Kanseri	SIA	5	2	-	%96,79	%78,57	%18,2	87	379	4,4	4
Meme Kanseri	SIA	5	3	-	%95,98	%82,14	%13,8	87	388	4,5	4

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Meme Kanseri	SIA	5	4	-	%97,19	%64,29	%32,9	92	376	4,1	4
Meme Kanseri	SIA	5	5	-	%97,19	%64,29	%32,9	89	304	3,4	4
Meme Kanseri	SIA	5	6	-	%97,59	%71,43	%26,2	88	346	3,9	4
Meme Kanseri	SIA	5	7	-	%96,80	%74,07	%22,7	93	322	3,5	4
Meme Kanseri	SIA	5	8	-	%98,40	%74,07	%24,3	90	330	3,7	4
Meme Kanseri	SIA	5	9	-	%97,20	%59,26	%37,9	86	336	3,9	4
Monkun prob. 2	ABCMiner	1	0	60.443	%96,91	%100	-3,1%	2	2	1	5,3
Monkun prob. 2	ABCMiner	1	1	60.449	%97,16	%97,73	-0,6%	2	2	1	5,1
Monkun prob. 2	ABCMiner	1	2	60.439	%97,16	%97,73	-0,6%	2	2	1	5,3
Monkun prob. 2	ABCMiner	1	3	60.429	%97,42	%95,45	%2	2	2	1	5,1
Monkun prob. 2	ABCMiner	1	4	60.458	%97,94	%90,91	%7	2	2	1	5
Monkun prob. 2	ABCMiner	1	5	60.443	%96,92	%100	-3,1%	2	2	1	5,2
Monkun prob. 2	ABCMiner	1	6	60.446	%97,42	%95,45	%2	2	2	1	5,2
Monkun prob. 2	ABCMiner	1	7	60.435	%96,95	%100	-3,0%	2	2	1	5,5
Monkun prob. 2	ABCMiner	1	8	60.442	%97,17	%97,67	-0,5%	2	2	1	5,2
Monkun prob. 2	ABCMiner	1	9	60.443	%97,16	%97,73	-0,6%	2	2	1	5,4
Monkun prob. 2	ABCMiner	2	0	60.445	%96,91	%100	-3,1%	2	2	1	5,4
Monkun prob. 2	ABCMiner	2	1	60.438	%97,16	%97,73	-0,6%	2	2	1	5,4
Monkun prob. 2	ABCMiner	2	2	60.436	%97,16	%97,73	-0,6%	2	2	1	5,3
Monkun prob. 2	ABCMiner	2	3	60.430	%97,42	%95,45	%2	2	2	1	5,2
Monkun prob. 2	ABCMiner	2	4	60.466	%97,94	%90,91	%7	2	2	1	5,2
Monkun prob. 2	ABCMiner	2	5	60.453	%96,92	%100	-3,1%	2	2	1	5,1
Monkun prob. 2	ABCMiner	2	6	60.440	%97,42	%95,45	%2	2	2	1	5,3
Monkun prob. 2	ABCMiner	2	7	60.435	%96,95	%100	-3,0%	2	2	1	5,5
Monkun prob. 2	ABCMiner	2	8	60.442	%97,17	%97,67	-0,5%	2	2	1	5,1
Monkun prob. 2	ABCMiner	2	9	60.446	%97,16	%97,73	-0,6%	2	2	1	5,2
Monkun prob. 2	ABCMiner	3	0	60.439	%96,91	%100	-3,1%	2	2	1	5,4
Monkun prob. 2	ABCMiner	3	1	60.445	%97,16	%97,73	-0,6%	2	2	1	5,2
Monkun prob. 2	ABCMiner	3	2	60.439	%97,16	%97,73	-0,6%	2	2	1	5,4
Monkun prob. 2	ABCMiner	3	3	60.440	%97,42	%95,45	%2	2	2	1	5,1
Monkun prob. 2	ABCMiner	3	4	60.453	%97,94	%90,91	%7	2	2	1	5,2
Monkun prob. 2	ABCMiner	3	5	60.434	%96,92	%100	-3,1%	2	2	1	5,4
Monkun prob. 2	ABCMiner	3	6	60.442	%97,42	%95,45	%2	2	2	1	5,1
Monkun prob. 2	ABCMiner	3	7	60.440	%96,95	%100	-3,0%	2	2	1	5,5
Monkun prob. 2	ABCMiner	3	8	60.437	%97,17	%97,67	-0,5%	2	2	1	5,2
Monkun prob. 2	ABCMiner	3	9	60.439	%97,16	%97,73	-0,6%	2	2	1	5
Monkun prob. 2	ABCMiner	4	0	60.456	%96,91	%100	-3,1%	2	2	1	4,9
Monkun prob. 2	ABCMiner	4	1	60.439	%97,16	%97,73	-0,6%	2	2	1	5,1
Monkun prob. 2	ABCMiner	4	2	60.440	%97,16	%97,73	-0,6%	2	2	1	5,2
Monkun prob. 2	ABCMiner	4	3	60.438	%97,42	%95,45	%2	2	2	1	5
Monkun prob. 2	ABCMiner	4	4	60.445	%97,94	%90,91	%7	2	2	1	5
Monkun prob. 2	ABCMiner	4	5	60.419	%96,92	%100	-3,1%	2	2	1	5,1
Monkun prob. 2	ABCMiner	4	6	60.442	%97,42	%95,45	%2	2	2	1	5,1
Monkun prob. 2	ABCMiner	4	7	60.437	%96,95	%100	-3,0%	2	2	1	5,2
Monkun prob. 2	ABCMiner	4	8	60.435	%97,17	%97,67	-0,5%	2	2	1	5,1
Monkun prob. 2	ABCMiner	4	9	60.451	%97,16	%97,73	-0,6%	2	2	1	4,9
Monkun prob. 2	ABCMiner	5	0	60.446	%96,91	%100	-3,1%	2	2	1	5,1
Monkun prob. 2	ABCMiner	5	1	60.446	%97,16	%97,73	-0,6%	2	2	1	4,8
Monkun prob. 2	ABCMiner	5	2	60.444	%97,16	%97,73	-0,6%	2	2	1	5,2
Monkun prob. 2	ABCMiner	5	3	60.442	%97,42	%95,45	%2	2	2	1	5
Monkun prob. 2	ABCMiner	5	4	60.438	%97,94	%90,91	%7	2	2	1	5,1
Monkun prob. 2	ABCMiner	5	5	60.435	%96,92	%100	-3,1%	2	2	1	5
Monkun prob. 2	ABCMiner	5	6	60.450	%97,42	%95,45	%2	2	2	1	5,1
Monkun prob. 2	ABCMiner	5	7	60.443	%96,95	%100	-3,0%	2	2	1	4,9
Monkun prob. 2	ABCMiner	5	8	60.436	%97,17	%97,67	-0,5%	2	2	1	5,2
Monkun prob. 2	ABCMiner	5	9	60.444	%97,16	%97,73	-0,6%	2	2	1	5,1
Monkun prob. 2	C4.5	-	1	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	2	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	3	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	4	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	5	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	6	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	7	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	8	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	9	-	%100	%100	%0	5	5	1	0,1
Monkun prob. 2	C4.5	-	10	-	%100	%100	%0	5	5	1	0,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Monkun prob. 2	CoABCMiner	1	0	110.851	%96,91	%100	-3,1%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	1	1	110.855	%97,16	%97,73	-0,6%	3	4	1,3	1,9
Monkun prob. 2	CoABCMiner	1	2	110.837	%97,16	%97,73	-0,6%	3	4	1,3	1,9
Monkun prob. 2	CoABCMiner	1	3	110.833	%97,42	%95,45	%2	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	1	4	110.850	%97,94	%90,91	%7	3	4	1,3	1,9
Monkun prob. 2	CoABCMiner	1	5	110.852	%96,92	%100	-3,1%	3	4	1,3	1,7
Monkun prob. 2	CoABCMiner	1	6	110.857	%97,42	%95,45	%2	3	3	1	2
Monkun prob. 2	CoABCMiner	1	7	110.845	%96,95	%100	-3,0%	3	3	1	1,9
Monkun prob. 2	CoABCMiner	1	8	110.853	%97,17	%97,67	-0,5%	4	4	1	1,9
Monkun prob. 2	CoABCMiner	1	9	110.840	%97,16	%97,73	-0,6%	3	4	1,3	2,3
Monkun prob. 2	CoABCMiner	2	0	110.851	%96,91	%100	-3,1%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	2	1	110.842	%97,16	%97,73	-0,6%	3	4	1,3	2
Monkun prob. 2	CoABCMiner	2	2	110.850	%97,16	%97,73	-0,6%	3	4	1,3	1,7
Monkun prob. 2	CoABCMiner	2	3	110.838	%97,42	%95,45	%2	3	4	1,3	1,9
Monkun prob. 2	CoABCMiner	2	4	110.858	%97,94	%90,91	%7	3	4	1,3	2,1
Monkun prob. 2	CoABCMiner	2	5	110.839	%96,92	%100	-3,1%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	2	6	110.852	%97,42	%95,45	%2	3	4	1,3	2,2
Monkun prob. 2	CoABCMiner	2	7	110.840	%96,95	%100	-3,0%	3	4	1,3	2,2
Monkun prob. 2	CoABCMiner	2	8	110.842	%97,17	%97,67	-0,5%	3	4	1,3	2,2
Monkun prob. 2	CoABCMiner	2	9	110.847	%97,16	%97,73	-0,6%	3	4	1,3	2,2
Monkun prob. 2	CoABCMiner	3	0	110.836	%96,91	%100	-3,1%	3	4	1,3	2
Monkun prob. 2	CoABCMiner	3	1	110.835	%97,16	%97,73	-0,6%	3	4	1,3	2,1
Monkun prob. 2	CoABCMiner	3	2	110.832	%97,16	%97,73	-0,6%	3	4	1,3	2
Monkun prob. 2	CoABCMiner	3	3	110.835	%97,42	%95,45	%2	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	3	4	110.856	%97,94	%90,91	%7	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	3	5	110.838	%96,92	%100	-3,1%	3	4	1,3	2
Monkun prob. 2	CoABCMiner	3	6	110.849	%97,42	%95,45	%2	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	3	7	110.842	%96,95	%100	-3,0%	3	4	1,3	1,7
Monkun prob. 2	CoABCMiner	3	8	110.847	%97,17	%97,67	-0,5%	3	4	1,3	2
Monkun prob. 2	CoABCMiner	3	9	110.840	%97,16	%97,73	-0,6%	3	4	1,3	1,9
Monkun prob. 2	CoABCMiner	4	0	110.851	%96,91	%100	-3,1%	3	3	1	2
Monkun prob. 2	CoABCMiner	4	1	110.825	%97,16	%97,73	-0,6%	3	3	1	1,8
Monkun prob. 2	CoABCMiner	4	2	110.851	%97,16	%97,73	-0,6%	3	3	1	1,8
Monkun prob. 2	CoABCMiner	4	3	110.846	%97,42	%95,45	%2	3	3	1	2
Monkun prob. 2	CoABCMiner	4	4	110.858	%97,94	%90,91	%7	3	3	1	1,7
Monkun prob. 2	CoABCMiner	4	5	110.834	%96,92	%100	-3,1%	3	3	1	1,8
Monkun prob. 2	CoABCMiner	4	6	110.840	%97,42	%95,45	%2	3	3	1	1,9
Monkun prob. 2	CoABCMiner	4	7	110.836	%96,95	%100	-3,0%	3	3	1	1,9
Monkun prob. 2	CoABCMiner	4	8	110.846	%97,17	%97,67	-0,5%	3	3	1	1,8
Monkun prob. 2	CoABCMiner	4	9	110.854	%97,16	%97,73	-0,6%	3	3	1	1,9
Monkun prob. 2	CoABCMiner	5	0	110.849	%96,91	%100	-3,1%	3	4	1,3	1,7
Monkun prob. 2	CoABCMiner	5	1	110.837	%97,16	%97,73	-0,6%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	2	110.834	%97,16	%97,73	-0,6%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	3	110.849	%97,42	%95,45	%2	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	4	110.849	%97,94	%90,91	%7	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	5	110.850	%96,92	%100	-3,1%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	6	110.827	%97,42	%95,45	%2	3	4	1,3	1,9
Monkun prob. 2	CoABCMiner	5	7	110.848	%96,95	%100	-3,0%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	8	110.843	%97,17	%97,67	-0,5%	3	4	1,3	1,8
Monkun prob. 2	CoABCMiner	5	9	110.841	%97,16	%97,73	-0,6%	3	4	1,3	1,9
Monkun prob. 2	CORE	1	0	1.968.386	%96,91	%100	-3,1%	2	2	1	43,2
Monkun prob. 2	CORE	1	1	1.965.264	%100	%100	%0	5	7	1,4	47,8
Monkun prob. 2	CORE	1	2	1.966.755	%97,16	%97,73	-0,6%	2	2	1	48
Monkun prob. 2	CORE	1	3	1.967.035	%97,42	%95,45	%2	2	2	1	45,6
Monkun prob. 2	CORE	1	4	1.965.181	%100	%100	%0	8	8	1	45,5
Monkun prob. 2	CORE	1	5	1.965.305	%96,92	%100	-3,1%	2	2	1	44
Monkun prob. 2	CORE	1	6	1.964.339	%97,42	%95,45	%2	2	2	1	47,1
Monkun prob. 2	CORE	1	7	1.965.954	%96,95	%100	-3,0%	2	2	1	47
Monkun prob. 2	CORE	1	8	1.965.922	%97,17	%97,67	-0,5%	2	2	1	47,3
Monkun prob. 2	CORE	1	9	1.965.458	%97,16	%97,73	-0,6%	2	2	1	44,4
Monkun prob. 2	CORE	2	0	-	%96,91	%100	-3,1%	2	2	1	45,9
Monkun prob. 2	CORE	2	1	-	%97,16	%97,73	-0,6%	2	2	1	44,7
Monkun prob. 2	CORE	2	2	-	%100	%100	%0	4	6	1,5	49,6
Monkun prob. 2	CORE	2	3	-	%100	%100	%0	5	6	1,2	45
Monkun prob. 2	CORE	2	4	-	%97,94	%90,91	%7	2	2	1	46,6
Monkun prob. 2	CORE	2	5	-	%100	%100	%0	5	8	1,6	45,6

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Monkun prob. 2	CORE	2	6	-	%97,42	%95,45	%2	2	2	1	44,9
Monkun prob. 2	CORE	2	7	-	%97,46	%94,74	%2,7	6	11	1,8	48,6
Monkun prob. 2	CORE	2	8	-	%97,69	%93,02	%4,7	7	11	1,6	44,7
Monkun prob. 2	CORE	2	9	-	%97,16	%97,73	-0,6%	2	2	1	42,8
Monkun prob. 2	CORE	3	0	-	%96,91	%100	-3,1%	2	2	1	44,3
Monkun prob. 2	CORE	3	1	-	%97,42	%95,45	%2	4	5	1,3	41,3
Monkun prob. 2	CORE	3	2	-	%97,16	%97,73	-0,6%	2	2	1	43,5
Monkun prob. 2	CORE	3	3	-	%100	%100	%0	5	8	1,6	47,1
Monkun prob. 2	CORE	3	4	-	%97,94	%90,91	%7	2	2	1	44,9
Monkun prob. 2	CORE	3	5	-	%97,17	%97,67	-0,5%	4	4	1	45,2
Monkun prob. 2	CORE	3	6	-	%97,42	%95,45	%2	2	2	1	43,3
Monkun prob. 2	CORE	3	7	-	%100	%100	%0	11	16	1,5	44,2
Monkun prob. 2	CORE	3	8	-	%98,20	%97,67	%0,5	5	8	1,6	46,3
Monkun prob. 2	CORE	3	9	-	%97,16	%97,73	-0,6%	2	2	1	42,4
Monkun prob. 2	CORE	4	0	-	%96,91	%100	-3,1%	2	2	1	46
Monkun prob. 2	CORE	4	1	-	%100	%100	%0	5	8	1,6	45,8
Monkun prob. 2	CORE	4	2	-	%97,42	%95,45	%2	5	7	1,4	45,9
Monkun prob. 2	CORE	4	3	-	%100	%100	%0	5	6	1,2	44,8
Monkun prob. 2	CORE	4	4	-	%97,94	%90,91	%7	2	2	1	45,8
Monkun prob. 2	CORE	4	5	-	%96,92	%100	-3,1%	2	2	1	46,3
Monkun prob. 2	CORE	4	6	-	%97,94	%95,45	%2,5	9	13	1,4	44,5
Monkun prob. 2	CORE	4	7	-	%96,95	%100	-3,0%	2	2	1	46,1
Monkun prob. 2	CORE	4	8	-	%97,17	%97,67	-0,5%	2	2	1	46,1
Monkun prob. 2	CORE	4	9	-	%97,16	%97,73	-0,6%	2	2	1	44,9
Monkun prob. 2	CORE	5	0	-	%97,16	%97,73	-0,6%	5	8	1,6	47,3
Monkun prob. 2	CORE	5	1	-	%100	%100	%0	9	14	1,6	45,4
Monkun prob. 2	CORE	5	2	-	%97,16	%97,73	-0,6%	2	2	1	47
Monkun prob. 2	CORE	5	3	-	%100	%100	%0	10	13	1,3	45,5
Monkun prob. 2	CORE	5	4	-	%97,94	%90,91	%7	2	2	1	44,2
Monkun prob. 2	CORE	5	5	-	%96,92	%100	-3,1%	2	2	1	42,6
Monkun prob. 2	CORE	5	6	-	%97,42	%95,45	%2	2	2	1	48,2
Monkun prob. 2	CORE	5	7	-	%96,95	%100	-3,0%	2	2	1	42,2
Monkun prob. 2	CORE	5	8	-	%100	%100	%0	11	15	1,4	48,2
Monkun prob. 2	CORE	5	9	-	%97,16	%97,73	-0,6%	2	2	1	45
Monkun prob. 2	HIDER	1	0	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	1	1	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	1	2	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	1	3	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	1	4	-	%97,90	%90,90	%7	2	2	1	4
Monkun prob. 2	HIDER	1	5	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	1	6	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	1	7	-	%97,00	%100	-3,0%	2	2	1	4
Monkun prob. 2	HIDER	1	8	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	1	9	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	2	0	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	2	1	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	2	2	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	2	3	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	2	4	-	%97,90	%90,90	%7	2	2	1	4
Monkun prob. 2	HIDER	2	5	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	2	6	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	2	7	-	%97,00	%100	-3,0%	2	2	1	4
Monkun prob. 2	HIDER	2	8	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	2	9	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	3	0	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	3	1	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	3	2	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	3	3	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	3	4	-	%97,90	%90,90	%7	2	2	1	4
Monkun prob. 2	HIDER	3	5	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	3	6	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	3	7	-	%97,00	%100	-3,0%	2	2	1	4
Monkun prob. 2	HIDER	3	8	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	3	9	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	4	0	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	4	1	-	%97,20	%97,70	-0,5%	2	2	1	4

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Monkun prob. 2	HIDER	4	2	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	4	3	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	4	4	-	%97,90	%90,90	%7	2	2	1	4
Monkun prob. 2	HIDER	4	5	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	4	6	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	4	7	-	%97,00	%100	-3,0%	2	2	1	4
Monkun prob. 2	HIDER	4	8	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	4	9	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	5	0	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	5	1	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	5	2	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	5	3	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	5	4	-	%97,90	%90,90	%7	2	2	1	4
Monkun prob. 2	HIDER	5	5	-	%96,90	%100	-3,1%	2	2	1	4
Monkun prob. 2	HIDER	5	6	-	%97,40	%95,50	%1,9	2	2	1	4
Monkun prob. 2	HIDER	5	7	-	%97,00	%100	-3,0%	2	2	1	4
Monkun prob. 2	HIDER	5	8	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	HIDER	5	9	-	%97,20	%97,70	-0,5%	2	2	1	4
Monkun prob. 2	LDWPSO	1	0	60.033	%96,91	%100	-3,1%	2	2	1	7,2
Monkun prob. 2	LDWPSO	1	1	60.031	%97,16	%97,73	-0,6%	2	2	1	7,5
Monkun prob. 2	LDWPSO	1	2	60.031	%97,16	%97,73	-0,6%	2	2	1	8,3
Monkun prob. 2	LDWPSO	1	3	60.031	%97,42	%95,45	%2	2	2	1	9
Monkun prob. 2	LDWPSO	1	4	60.028	%97,94	%90,91	%7	2	2	1	8,6
Monkun prob. 2	LDWPSO	1	5	80.042	%100	%100	%0	5	5	1	9,4
Monkun prob. 2	LDWPSO	1	6	60.030	%97,42	%95,45	%2	2	2	1	9,3
Monkun prob. 2	LDWPSO	1	7	80.041	%100	%100	%0	5	5	1	10,1
Monkun prob. 2	LDWPSO	1	8	80.038	%97,43	%95,35	%2,1	5	5	1	9,7
Monkun prob. 2	LDWPSO	1	9	60.025	%80,67	%79,55	%1,1	2	1	0,5	8,3
Monkun prob. 2	LDWPSO	2	0	20.011	%77,06	%84,09	-7,0%	2	1	0,5	5,9
Monkun prob. 2	LDWPSO	2	1	20.011	%77,32	%81,82	-4,5%	2	1	0,5	6,6
Monkun prob. 2	LDWPSO	2	2	20.011	%77,32	%81,82	-4,5%	2	1	0,5	6,1
Monkun prob. 2	LDWPSO	2	3	20.011	%77,32	%81,82	-4,5%	2	1	0,5	6,8
Monkun prob. 2	LDWPSO	2	4	20.009	%77,32	%81,82	-4,5%	2	1	0,5	6
Monkun prob. 2	LDWPSO	2	5	20.009	%78,15	%74,42	%3,7	2	1	0,5	6,3
Monkun prob. 2	LDWPSO	2	6	20.011	%78,61	%70,45	%8,2	2	1	0,5	6,4
Monkun prob. 2	LDWPSO	2	7	20.011	%79,19	%63,16	%16	2	1	0,5	6,9
Monkun prob. 2	LDWPSO	2	8	20.011	%78,15	%74,42	%3,7	2	1	0,5	6,4
Monkun prob. 2	LDWPSO	2	9	20.011	%77,32	%81,82	-4,5%	2	1	0,5	6
Monkun prob. 2	LDWPSO	3	0	60.026	%96,91	%100	-3,1%	2	2	1	8,7
Monkun prob. 2	LDWPSO	3	1	60.023	%80,67	%79,55	%1,1	2	1	0,5	9
Monkun prob. 2	LDWPSO	3	2	60.024	%97,16	%97,73	-0,6%	2	2	1	8,4
Monkun prob. 2	LDWPSO	3	3	60.030	%97,42	%95,45	%2	2	2	1	8,6
Monkun prob. 2	LDWPSO	3	4	60.030	%97,94	%90,91	%7	2	2	1	8,5
Monkun prob. 2	LDWPSO	3	5	60.030	%96,92	%100	-3,1%	2	2	1	9,5
Monkun prob. 2	LDWPSO	3	6	60.030	%97,42	%95,45	%2	2	2	1	9,3
Monkun prob. 2	LDWPSO	3	7	60.026	%96,95	%100	-3,0%	2	2	1	8,7
Monkun prob. 2	LDWPSO	3	8	60.026	%97,17	%97,67	-0,5%	2	2	1	8,3
Monkun prob. 2	LDWPSO	3	9	60.023	%80,67	%79,55	%1,1	2	1	0,5	7,7
Monkun prob. 2	LDWPSO	4	0	60.034	%96,91	%100	-3,1%	2	2	1	9,4
Monkun prob. 2	LDWPSO	4	1	60.032	%97,16	%97,73	-0,6%	2	2	1	9,7
Monkun prob. 2	LDWPSO	4	2	60.032	%97,16	%97,73	-0,6%	2	2	1	9,2
Monkun prob. 2	LDWPSO	4	3	60.032	%97,42	%95,45	%2	2	2	1	8,6
Monkun prob. 2	LDWPSO	4	4	60.032	%97,94	%90,91	%7	2	2	1	9,3
Monkun prob. 2	LDWPSO	4	5	60.030	%96,92	%100	-3,1%	2	2	1	9
Monkun prob. 2	LDWPSO	4	6	60.032	%97,42	%95,45	%2	2	2	1	8,4
Monkun prob. 2	LDWPSO	4	7	60.034	%96,95	%100	-3,0%	2	2	1	8,6
Monkun prob. 2	LDWPSO	4	8	60.034	%97,17	%97,67	-0,5%	2	2	1	8
Monkun prob. 2	LDWPSO	4	9	60.032	%97,16	%97,73	-0,6%	2	2	1	7,4
Monkun prob. 2	LDWPSO	5	0	60.030	%96,91	%100	-3,1%	2	2	1	7,1
Monkun prob. 2	LDWPSO	5	1	60.030	%97,16	%97,73	-0,6%	2	2	1	7,1
Monkun prob. 2	LDWPSO	5	2	60.032	%97,16	%97,73	-0,6%	2	2	1	7,1
Monkun prob. 2	LDWPSO	5	3	60.031	%97,42	%95,45	%2	2	2	1	6,9
Monkun prob. 2	LDWPSO	5	4	60.031	%97,94	%90,91	%7	2	2	1	7,1
Monkun prob. 2	LDWPSO	5	5	80.042	%97,17	%97,67	-0,5%	5	5	1	7,7
Monkun prob. 2	LDWPSO	5	6	60.031	%97,42	%95,45	%2	2	2	1	7,2
Monkun prob. 2	LDWPSO	5	7	80.038	%97,21	%97,37	-0,2%	5	5	1	7,9

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Monkun prob. 2	LDWPSO	5	8	60.031	%97,17	%97,67	-0,5%	2	2	1	7
Monkun prob. 2	LDWPSO	5	9	60.032	%97,16	%97,73	-0,6%	2	2	1	7,3
Monkun prob. 2	PGIRLA	1	0	-	%96,91	%100	-3,1%	20	40	2	1
Monkun prob. 2	PGIRLA	1	1	-	%97,16	%97,73	-0,6%	20	39	2	1
Monkun prob. 2	PGIRLA	1	2	-	%97,16	%97,73	-0,6%	20	42	2,1	2
Monkun prob. 2	PGIRLA	1	3	-	%97,42	%95,45	%2	20	46	2,3	1
Monkun prob. 2	PGIRLA	1	4	-	%97,94	%90,91	%7	20	38	1,9	1
Monkun prob. 2	PGIRLA	1	5	-	%96,92	%100	-3,1%	20	53	2,7	2
Monkun prob. 2	PGIRLA	1	6	-	%97,42	%95,45	%2	20	45	2,3	1
Monkun prob. 2	PGIRLA	1	7	-	%96,95	%100	-3,0%	20	41	2,1	1
Monkun prob. 2	PGIRLA	1	8	-	%97,17	%97,67	-0,5%	20	42	2,1	1
Monkun prob. 2	PGIRLA	1	9	-	%97,16	%97,73	-0,6%	20	41	2,1	2
Monkun prob. 2	PGIRLA	2	0	-	%96,91	%100	-3,1%	20	46	2,3	1
Monkun prob. 2	PGIRLA	2	1	-	%97,16	%97,73	-0,6%	20	53	2,7	1
Monkun prob. 2	PGIRLA	2	2	-	%97,16	%97,73	-0,6%	20	45	2,3	2
Monkun prob. 2	PGIRLA	2	3	-	%97,42	%95,45	%2	20	51	2,6	1
Monkun prob. 2	PGIRLA	2	4	-	%97,94	%90,91	%7	20	42	2,1	1
Monkun prob. 2	PGIRLA	2	5	-	%96,92	%100	-3,1%	20	46	2,3	2
Monkun prob. 2	PGIRLA	2	6	-	%97,42	%95,45	%2	20	50	2,5	1
Monkun prob. 2	PGIRLA	2	7	-	%96,95	%100	-3,0%	20	55	2,8	1
Monkun prob. 2	PGIRLA	2	8	-	%97,17	%97,67	-0,5%	20	44	2,2	1
Monkun prob. 2	PGIRLA	2	9	-	%97,16	%97,73	-0,6%	20	53	2,7	2
Monkun prob. 2	PGIRLA	3	0	-	%96,91	%100	-3,1%	20	50	2,5	1
Monkun prob. 2	PGIRLA	3	1	-	%97,16	%97,73	-0,6%	20	49	2,5	1
Monkun prob. 2	PGIRLA	3	2	-	%97,16	%75,00	%22,2	20	49	2,5	2
Monkun prob. 2	PGIRLA	3	3	-	%97,42	%95,45	%2	20	44	2,2	1
Monkun prob. 2	PGIRLA	3	4	-	%97,94	%90,91	%7	20	46	2,3	1
Monkun prob. 2	PGIRLA	3	5	-	%96,92	%100	-3,1%	20	34	1,7	2
Monkun prob. 2	PGIRLA	3	6	-	%97,42	%95,45	%2	20	47	2,4	1
Monkun prob. 2	PGIRLA	3	7	-	%96,95	%55,26	%41,7	20	44	2,2	1
Monkun prob. 2	PGIRLA	3	8	-	%97,17	%97,67	-0,5%	20	43	2,2	1
Monkun prob. 2	PGIRLA	3	9	-	%97,16	%97,73	-0,6%	20	48	2,4	2
Monkun prob. 2	PGIRLA	4	0	-	%96,91	%100	-3,1%	20	55	2,8	1
Monkun prob. 2	PGIRLA	4	1	-	%97,16	%97,73	-0,6%	20	52	2,6	1
Monkun prob. 2	PGIRLA	4	2	-	%97,16	%97,73	-0,6%	20	50	2,5	2
Monkun prob. 2	PGIRLA	4	3	-	%89,43	%84,09	%5,3	20	50	2,5	1
Monkun prob. 2	PGIRLA	4	4	-	%97,94	%90,91	%7	20	41	2,1	1
Monkun prob. 2	PGIRLA	4	5	-	%96,92	%100	-3,1%	20	49	2,5	2
Monkun prob. 2	PGIRLA	4	6	-	%97,42	%95,45	%2	20	47	2,4	1
Monkun prob. 2	PGIRLA	4	7	-	%96,95	%100	-3,0%	20	49	2,5	1
Monkun prob. 2	PGIRLA	4	8	-	%97,17	%97,67	-0,5%	20	45	2,3	1
Monkun prob. 2	PGIRLA	4	9	-	%97,16	%97,73	-0,6%	20	50	2,5	2
Monkun prob. 2	PGIRLA	5	0	-	%96,91	%100	-3,1%	20	51	2,6	1
Monkun prob. 2	PGIRLA	5	1	-	%97,16	%97,73	-0,6%	20	49	2,5	1
Monkun prob. 2	PGIRLA	5	2	-	%97,16	%97,73	-0,6%	20	43	2,2	2
Monkun prob. 2	PGIRLA	5	3	-	%97,42	%95,45	%2	20	39	2	1
Monkun prob. 2	PGIRLA	5	4	-	%97,94	%90,91	%7	20	36	1,8	1
Monkun prob. 2	PGIRLA	5	5	-	%96,92	%100	-3,1%	20	37	1,9	2
Monkun prob. 2	PGIRLA	5	6	-	%97,42	%95,45	%2	20	43	2,2	1
Monkun prob. 2	PGIRLA	5	7	-	%96,95	%100	-3,0%	20	42	2,1	1
Monkun prob. 2	PGIRLA	5	8	-	%97,17	%97,67	-0,5%	20	47	2,4	1
Monkun prob. 2	PGIRLA	5	9	-	%97,16	%97,73	-0,6%	20	50	2,5	2
Monkun prob. 2	SIA	1	0	-	%63,40	%68,18	-4,8%	18	82	4,6	1
Monkun prob. 2	SIA	1	1	-	%54,90	%61,36	-6,5%	17	76	4,5	1
Monkun prob. 2	SIA	1	2	-	%65,46	%50,00	%15,5	17	78	4,6	1
Monkun prob. 2	SIA	1	3	-	%64,18	%61,36	%2,8	18	79	4,4	1
Monkun prob. 2	SIA	1	4	-	%63,92	%63,64	%0,3	18	76	4,2	1
Monkun prob. 2	SIA	1	5	-	%63,75	%65,12	-1,4%	18	78	4,3	1
Monkun prob. 2	SIA	1	6	-	%64,18	%61,36	%2,8	18	74	4,1	1
Monkun prob. 2	SIA	1	7	-	%63,45	%68,42	-5,0%	18	70	3,9	1
Monkun prob. 2	SIA	1	8	-	%64,01	%62,79	%1,2	18	81	4,5	1
Monkun prob. 2	SIA	1	9	-	%54,90	%61,36	-6,5%	17	79	4,6	1
Monkun prob. 2	SIA	2	0	-	%63,40	%68,18	-4,8%	18	74	4,1	1
Monkun prob. 2	SIA	2	1	-	%63,66	%65,91	-2,2%	18	72	4	1
Monkun prob. 2	SIA	2	2	-	%65,46	%50,00	%15,5	18	77	4,3	1
Monkun prob. 2	SIA	2	3	-	%64,18	%61,36	%2,8	18	80	4,4	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Monkun prob. 2	SIA	2	4	-	%55,67	%54,55	%1,1	17	81	4,8	1
Monkun prob. 2	SIA	2	5	-	%63,75	%65,12	-1,4%	18	82	4,6	1
Monkun prob. 2	SIA	2	6	-	%64,18	%61,36	%2,8	18	75	4,2	1
Monkun prob. 2	SIA	2	7	-	%54,82	%63,16	-8,3%	17	73	4,3	1
Monkun prob. 2	SIA	2	8	-	%55,53	%55,81	-0,3%	16	70	4,4	1
Monkun prob. 2	SIA	2	9	-	%55,15	%59,09	-3,9%	17	72	4,2	1
Monkun prob. 2	SIA	3	0	-	%63,40	%68,18	-4,8%	18	80	4,4	1
Monkun prob. 2	SIA	3	1	-	%63,66	%65,91	-2,2%	18	73	4,1	1
Monkun prob. 2	SIA	3	2	-	%65,46	%50,00	%15,5	18	70	3,9	1
Monkun prob. 2	SIA	3	3	-	%64,18	%61,36	%2,8	18	75	4,2	1
Monkun prob. 2	SIA	3	4	-	%55,41	%56,82	-1,4%	17	71	4,2	1
Monkun prob. 2	SIA	3	5	-	%63,75	%65,12	-1,4%	18	77	4,3	1
Monkun prob. 2	SIA	3	6	-	%64,18	%61,36	%2,8	18	76	4,2	1
Monkun prob. 2	SIA	3	7	-	%63,45	%68,42	-5,0%	18	81	4,5	1
Monkun prob. 2	SIA	3	8	-	%64,01	%62,79	%1,2	18	71	3,9	1
Monkun prob. 2	SIA	3	9	-	%62,89	%72,73	-9,8%	18	73	4,1	1
Monkun prob. 2	SIA	4	0	-	%63,40	%68,18	-4,8%	18	86	4,8	1
Monkun prob. 2	SIA	4	1	-	%63,66	%65,91	-2,2%	18	69	3,8	1
Monkun prob. 2	SIA	4	2	-	%65,46	%50,00	%15,5	18	71	3,9	1
Monkun prob. 2	SIA	4	3	-	%64,18	%61,36	%2,8	18	79	4,4	1
Monkun prob. 2	SIA	4	4	-	%63,92	%63,64	%0,3	18	79	4,4	1
Monkun prob. 2	SIA	4	5	-	%63,75	%65,12	-1,4%	18	81	4,5	1
Monkun prob. 2	SIA	4	6	-	%64,18	%61,36	%2,8	18	70	3,9	1
Monkun prob. 2	SIA	4	7	-	%63,45	%68,42	-5,0%	18	70	3,9	1
Monkun prob. 2	SIA	4	8	-	%64,01	%62,79	%1,2	18	80	4,4	1
Monkun prob. 2	SIA	4	9	-	%62,89	%72,73	-9,8%	18	74	4,1	1
Monkun prob. 2	SIA	5	0	-	%63,40	%68,18	-4,8%	17	79	4,6	1
Monkun prob. 2	SIA	5	1	-	%63,66	%65,91	-2,2%	18	68	3,8	1
Monkun prob. 2	SIA	5	2	-	%65,46	%50,00	%15,5	18	73	4,1	1
Monkun prob. 2	SIA	5	3	-	%64,18	%61,36	%2,8	17	78	4,6	1
Monkun prob. 2	SIA	5	4	-	%55,41	%56,82	-1,4%	17	77	4,5	1
Monkun prob. 2	SIA	5	5	-	%63,75	%65,12	-1,4%	17	70	4,1	1
Monkun prob. 2	SIA	5	6	-	%55,15	%59,09	-3,9%	17	75	4,4	1
Monkun prob. 2	SIA	5	7	-	%54,82	%63,16	-8,3%	17	77	4,5	1
Monkun prob. 2	SIA	5	8	-	%64,01	%62,79	%1,2	18	81	4,5	1
Monkun prob. 2	SIA	5	9	-	%62,89	%72,73	-9,8%	17	78	4,6	1
Soya Fasülyesi	ABCMiner	1	0	176.877	%64,82	%60,87	%4	17	39	2,3	5.752,3
Soya Fasülyesi	ABCMiner	1	1	198.040	%62,05	%63,77	-1,7%	16	42	2,6	5.630,6
Soya Fasülyesi	ABCMiner	1	2	221.072	%66,29	%66,67	-0,4%	17	40	2,4	6.763,4
Soya Fasülyesi	ABCMiner	1	3	181.715	%64,88	%72,06	-7,2%	17	48	2,8	6.134,8
Soya Fasülyesi	ABCMiner	1	4	193.521	%63,74	%57,35	%6,4	17	46	2,7	5.988,9
Soya Fasülyesi	ABCMiner	1	5	231.248	%64,07	%60,29	%3,8	16	37	2,3	6.618,7
Soya Fasülyesi	ABCMiner	1	6	207.788	%66,18	%64,71	%1,5	16	41	2,6	6.778,8
Soya Fasülyesi	ABCMiner	1	7	207.399	%68,13	%58,82	%9,3	16	43	2,7	6.302,6
Soya Fasülyesi	ABCMiner	1	8	181.868	%63,09	%61,76	%1,3	16	32	2	5.815,2
Soya Fasülyesi	ABCMiner	1	9	220.456	%66,02	%63,24	%2,8	16	39	2,4	6.187,5
Soya Fasülyesi	ABCMiner	2	0	220.943	%59,61	%59,42	%0,2	16	36	2,3	6.245,2
Soya Fasülyesi	ABCMiner	2	1	168.000	%61,73	%63,77	-2,0%	16	32	2	5.859,9
Soya Fasülyesi	ABCMiner	2	2	180.083	%57,82	%56,52	%1,3	16	38	2,4	5.872,4
Soya Fasülyesi	ABCMiner	2	3	213.130	%70,41	%77,94	-7,5%	17	38	2,2	6.189,9
Soya Fasülyesi	ABCMiner	2	4	223.349	%65,04	%63,24	%1,8	17	45	2,6	6.274,4
Soya Fasülyesi	ABCMiner	2	5	175.675	%71,22	%73,53	-2,3%	16	34	2,1	5.664,5
Soya Fasülyesi	ABCMiner	2	6	205.368	%66,50	%61,76	%4,7	16	36	2,3	6.142,8
Soya Fasülyesi	ABCMiner	2	7	216.825	%64,07	%64,71	-0,6%	16	34	2,1	6.350,4
Soya Fasülyesi	ABCMiner	2	8	171.275	%60,16	%57,35	%2,8	16	38	2,4	5.624
Soya Fasülyesi	ABCMiner	2	9	211.006	%71,22	%67,65	%3,6	17	41	2,4	6.286,2
Soya Fasülyesi	ABCMiner	3	0	207.204	%61,89	%59,42	%2,5	16	36	2,3	6.068,8
Soya Fasülyesi	ABCMiner	3	1	193.329	%63,36	%68,12	-4,8%	16	40	2,5	6.097,4
Soya Fasülyesi	ABCMiner	3	2	201.336	%62,38	%56,52	%5,9	15	32	2,1	6.021,2
Soya Fasülyesi	ABCMiner	3	3	206.769	%65,69	%73,53	-7,8%	16	34	2,1	6.060,2
Soya Fasülyesi	ABCMiner	3	4	206.068	%65,37	%67,65	-2,3%	17	43	2,5	6.333,5
Soya Fasülyesi	ABCMiner	3	5	193.918	%68,94	%73,53	-4,6%	17	39	2,3	5.882,1
Soya Fasülyesi	ABCMiner	3	6	188.802	%73,66	%66,18	%7,5	17	32	1,9	5.975,8
Soya Fasülyesi	ABCMiner	3	7	195.556	%66,99	%64,71	%2,3	16	40	2,5	6.108,1
Soya Fasülyesi	ABCMiner	3	8	197.985	%59,02	%50,00	%9	17	40	2,4	6.162,4
Soya Fasülyesi	ABCMiner	3	9	194.537	%64,88	%60,29	%4,6	16	37	2,3	6.026,8

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Soya Fasülyesi	ABCMiner	4	0	193.874	%73,62	%73,91	-0,3%	17	34	2	5.706,1
Soya Fasülyesi	ABCMiner	4	1	202.666	%64,17	%62,32	%1,9	16	42	2,6	5.560,1
Soya Fasülyesi	ABCMiner	4	2	195.249	%74,43	%71,01	%3,4	17	41	2,4	5.714,5
Soya Fasülyesi	ABCMiner	4	3	217.531	%58,70	%61,76	-3,1%	16	41	2,6	5.960,7
Soya Fasülyesi	ABCMiner	4	4	207.780	%62,28	%63,24	-1,0%	17	48	2,8	6.068,6
Soya Fasülyesi	ABCMiner	4	5	200.669	%70,89	%72,06	-1,2%	17	46	2,7	5.706,6
Soya Fasülyesi	ABCMiner	4	6	165.680	%69,76	%67,65	%2,1	15	36	2,4	5.092,5
Soya Fasülyesi	ABCMiner	4	7	167.326	%62,44	%66,18	-3,7%	16	34	2,1	5.111,8
Soya Fasülyesi	ABCMiner	4	8	184.165	%64,72	%57,35	%7,4	17	36	2,1	5.569,6
Soya Fasülyesi	ABCMiner	4	9	181.688	%62,60	%63,24	-0,6%	16	38	2,4	5.551
Soya Fasülyesi	ABCMiner	5	0	184.152	%66,12	%63,77	%2,4	16	42	2,6	5.710,6
Soya Fasülyesi	ABCMiner	5	1	180.642	%65,31	%66,67	-1,4%	16	35	2,2	5.576
Soya Fasülyesi	ABCMiner	5	2	178.222	%70,03	%71,01	-1,0%	17	39	2,3	5.289,5
Soya Fasülyesi	ABCMiner	5	3	222.339	%59,67	%63,24	-3,6%	16	40	2,5	5.995,5
Soya Fasülyesi	ABCMiner	5	4	199.384	%74,80	%73,53	%1,3	17	42	2,5	5.887,4
Soya Fasülyesi	ABCMiner	5	5	180.976	%67,80	%66,18	%1,6	16	38	2,4	5.487,8
Soya Fasülyesi	ABCMiner	5	6	187.491	%69,43	%66,18	%3,3	16	38	2,4	5.612,4
Soya Fasülyesi	ABCMiner	5	7	196.457	%65,20	%64,71	%0,5	16	35	2,2	5.699,1
Soya Fasülyesi	ABCMiner	5	8	213.174	%61,95	%54,41	%7,5	17	42	2,5	6.144,3
Soya Fasülyesi	ABCMiner	5	9	172.814	%63,25	%58,82	%4,4	16	38	2,4	5.266,6
Soya Fasülyesi	C4.5	-	1	-	%78,83	%73,91	%4,9	41	153	3,7	0,8
Soya Fasülyesi	C4.5	-	2	-	%80,29	%78,26	%2	38	135	3,6	0,8
Soya Fasülyesi	C4.5	-	3	-	%79,80	%81,16	-1,4%	39	158	4,1	0,8
Soya Fasülyesi	C4.5	-	4	-	%78,05	%73,53	%4,5	42	151	3,6	0,8
Soya Fasülyesi	C4.5	-	5	-	%78,70	%75,00	%3,7	40	135	3,4	0,8
Soya Fasülyesi	C4.5	-	6	-	%79,02	%75,00	%4	45	174	3,9	0,8
Soya Fasülyesi	C4.5	-	7	-	%79,67	%75,00	%4,7	41	163	4	0,8
Soya Fasülyesi	C4.5	-	8	-	%88,29	%85,29	%3	33	125	3,8	0,8
Soya Fasülyesi	C4.5	-	9	-	%87,97	%82,35	%5,6	35	124	3,5	0,8
Soya Fasülyesi	C4.5	-	10	-	%88,29	%83,82	%4,5	37	148	4	0,8
Soya Fasülyesi	CoABCMiner	1	0	110.550	%94,14	%91,30	%2,8	26	260	10	6,5
Soya Fasülyesi	CoABCMiner	1	1	110.567	%91,69	%95,65	-4,0%	28	299	10,7	6,1
Soya Fasülyesi	CoABCMiner	1	2	110.559	%93,49	%92,75	%0,7	28	283	10,1	6,2
Soya Fasülyesi	CoABCMiner	1	3	110.562	%91,54	%89,71	%1,8	27	243	9	6
Soya Fasülyesi	CoABCMiner	1	4	110.558	%92,85	%89,71	%3,1	24	205	8,5	5,9
Soya Fasülyesi	CoABCMiner	1	5	110.551	%91,22	%89,71	%1,5	26	262	10,1	6
Soya Fasülyesi	CoABCMiner	1	6	110.562	%92,20	%92,65	-0,5%	29	277	9,6	6,1
Soya Fasülyesi	CoABCMiner	1	7	110.550	%92,20	%88,24	%4	26	261	10	6,8
Soya Fasülyesi	CoABCMiner	1	8	110.558	%93,98	%91,18	%2,8	27	273	10,1	6,2
Soya Fasülyesi	CoABCMiner	1	9	110.561	%93,82	%88,24	%5,6	24	235	9,8	5,9
Soya Fasülyesi	CoABCMiner	2	0	110.561	%92,02	%86,96	%5,1	27	272	10,1	4,9
Soya Fasülyesi	CoABCMiner	2	1	110.550	%91,53	%84,06	%7,5	25	248	9,9	4,9
Soya Fasülyesi	CoABCMiner	2	2	110.559	%92,35	%89,86	%2,5	28	278	9,9	4,8
Soya Fasülyesi	CoABCMiner	2	3	110.562	%93,66	%95,59	-1,9%	22	223	10,1	5,4
Soya Fasülyesi	CoABCMiner	2	4	110.551	%91,54	%85,29	%6,3	29	321	11,1	6
Soya Fasülyesi	CoABCMiner	2	5	110.560	%92,36	%86,76	%5,6	29	285	9,8	5,7
Soya Fasülyesi	CoABCMiner	2	6	110.557	%90,41	%85,29	%5,1	27	252	9,3	5,8
Soya Fasülyesi	CoABCMiner	2	7	110.587	%91,22	%85,29	%5,9	27	283	10,5	5,7
Soya Fasülyesi	CoABCMiner	2	8	110.554	%92,36	%86,76	%5,6	27	285	10,6	6,2
Soya Fasülyesi	CoABCMiner	2	9	110.559	%90,08	%86,76	%3,3	24	232	9,7	6,5
Soya Fasülyesi	CoABCMiner	3	0	110.546	%93,49	%91,30	%2,2	22	212	9,6	6
Soya Fasülyesi	CoABCMiner	3	1	110.572	%91,53	%88,41	%3,1	30	287	9,6	5,9
Soya Fasülyesi	CoABCMiner	3	2	110.567	%94,14	%91,30	%2,8	24	237	9,9	6,6
Soya Fasülyesi	CoABCMiner	3	3	110.575	%92,52	%94,12	-1,6%	23	237	10,3	6,5
Soya Fasülyesi	CoABCMiner	3	4	110.560	%92,85	%88,24	%4,6	27	307	11,4	6
Soya Fasülyesi	CoABCMiner	3	5	110.556	%93,66	%94,12	-0,5%	26	278	10,7	6,1
Soya Fasülyesi	CoABCMiner	3	6	110.560	%93,66	%88,24	%5,4	27	263	9,7	6,2
Soya Fasülyesi	CoABCMiner	3	7	110.559	%90,57	%86,76	%3,8	26	285	11	6,1
Soya Fasülyesi	CoABCMiner	3	8	110.560	%93,50	%89,71	%3,8	30	327	10,9	6
Soya Fasülyesi	CoABCMiner	3	9	110.567	%92,36	%89,71	%2,7	28	253	9	6
Soya Fasülyesi	CoABCMiner	4	0	110.572	%94,46	%95,65	-1,2%	27	274	10,1	5,7
Soya Fasülyesi	CoABCMiner	4	1	110.573	%92,67	%94,20	-1,5%	26	260	10	6,1
Soya Fasülyesi	CoABCMiner	4	2	110.563	%92,51	%89,86	%2,7	26	249	9,6	6,2
Soya Fasülyesi	CoABCMiner	4	3	110.571	%93,98	%92,65	%1,3	26	250	9,6	6,4
Soya Fasülyesi	CoABCMiner	4	4	110.568	%93,50	%94,12	-0,6%	26	274	10,5	6,3
Soya Fasülyesi	CoABCMiner	4	5	110.566	%91,87	%94,12	-2,2%	27	266	9,9	6,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Soya Fasülyesi	CoABCMiner	4	6	110.569	%90,73	%89,71	%1	22	216	9,8	6
Soya Fasülyesi	CoABCMiner	4	7	110.561	%94,47	%88,24	%6,2	23	261	11,3	5,8
Soya Fasülyesi	CoABCMiner	4	8	110.570	%93,17	%89,71	%3,5	27	261	9,7	6
Soya Fasülyesi	CoABCMiner	4	9	110.554	%90,57	%86,76	%3,8	24	238	9,9	5,9
Soya Fasülyesi	CoABCMiner	5	0	110.567	%94,46	%88,41	%6,1	26	259	10	6,3
Soya Fasülyesi	CoABCMiner	5	1	110.559	%92,18	%91,30	%0,9	27	303	11,2	6
Soya Fasülyesi	CoABCMiner	5	2	110.553	%93,65	%89,86	%3,8	25	240	9,6	6
Soya Fasülyesi	CoABCMiner	5	3	110.551	%93,82	%95,59	-1,8%	25	231	9,2	6
Soya Fasülyesi	CoABCMiner	5	4	110.559	%91,38	%92,65	-1,3%	26	269	10,3	6
Soya Fasülyesi	CoABCMiner	5	5	110.576	%92,36	%89,71	%2,7	29	266	9,2	6,1
Soya Fasülyesi	CoABCMiner	5	6	110.553	%92,20	%91,18	%1	25	269	10,8	6,7
Soya Fasülyesi	CoABCMiner	5	7	110.569	%91,71	%88,24	%3,5	33	289	8,8	6,3
Soya Fasülyesi	CoABCMiner	5	8	110.567	%93,82	%88,24	%5,6	28	268	9,6	6,3
Soya Fasülyesi	CoABCMiner	5	9	110.582	%92,52	%85,29	%7,2	24	254	10,6	6,4
Soya Fasülyesi	CORE	1	0	1.965.521	%24,10	%23,19	%0,9	12	120	10	308,1
Soya Fasülyesi	CORE	1	1	1.963.763	%22,48	%23,19	-0,7%	14	166	11,9	307,4
Soya Fasülyesi	CORE	1	2	1.964.680	%21,50	%21,74	-0,2%	8	73	9,1	328,5
Soya Fasülyesi	CORE	1	3	1.964.833	%28,94	%29,41	-0,5%	12	132	11	288,8
Soya Fasülyesi	CORE	1	4	1.965.263	%23,74	%26,47	-2,7%	4	31	7,8	286,8
Soya Fasülyesi	CORE	1	5	1.966.051	%19,19	%19,12	%0,1	6	65	10,8	316,1
Soya Fasülyesi	CORE	1	6	1.965.034	%33,66	%27,94	%5,7	15	181	12,1	306,2
Soya Fasülyesi	CORE	1	7	1.965.272	%20,65	%23,53	-2,9%	11	124	11,3	292,2
Soya Fasülyesi	CORE	1	8	1.965.237	%16,91	%17,65	-0,7%	13	117	9	343,9
Soya Fasülyesi	CORE	1	9	1.966.313	%18,37	%20,59	-2,2%	3	22	7,3	296,2
Soya Fasülyesi	CORE	2	0	-	%22,96	%21,74	%1,2	3	20	6,7	286,5
Soya Fasülyesi	CORE	2	1	-	%22,15	%21,74	%0,4	5	39	7,8	254,5
Soya Fasülyesi	CORE	2	2	-	%26,38	%20,29	%6,1	10	112	11,2	302,3
Soya Fasülyesi	CORE	2	3	-	%21,46	%19,12	%2,3	10	94	9,4	283,7
Soya Fasülyesi	CORE	2	4	-	%24,39	%26,47	-2,1%	13	139	10,7	315,9
Soya Fasülyesi	CORE	2	5	-	%24,23	%22,06	%2,2	10	85	8,5	289,8
Soya Fasülyesi	CORE	2	6	-	%22,60	%20,59	%2	12	128	10,7	275
Soya Fasülyesi	CORE	2	7	-	%20,98	%20,59	%0,4	12	128	10,7	286,7
Soya Fasülyesi	CORE	2	8	-	%23,58	%26,47	-2,9%	14	136	9,7	303
Soya Fasülyesi	CORE	2	9	-	%24,55	%26,47	-1,9%	12	119	9,9	311,1
Soya Fasülyesi	CORE	3	0	-	%23,45	%27,54	-4,1%	14	135	9,6	294,7
Soya Fasülyesi	CORE	3	1	-	%19,38	%18,84	%0,5	8	115	14,4	326,3
Soya Fasülyesi	CORE	3	2	-	%19,06	%21,74	-2,7%	3	29	9,7	300,5
Soya Fasülyesi	CORE	3	3	-	%17,89	%17,65	%0,2	11	119	10,8	280,1
Soya Fasülyesi	CORE	3	4	-	%16,59	%16,18	%0,4	14	162	11,6	362,8
Soya Fasülyesi	CORE	3	5	-	%20,65	%19,12	%1,5	9	88	9,8	278,1
Soya Fasülyesi	CORE	3	6	-	%17,89	%17,65	%0,2	4	49	12,3	311,2
Soya Fasülyesi	CORE	3	7	-	%31,54	%32,35	-0,8%	11	116	10,5	294,4
Soya Fasülyesi	CORE	3	8	-	%16,75	%16,18	%0,6	12	159	13,3	331,2
Soya Fasülyesi	CORE	3	9	-	%23,41	%19,12	%4,3	13	138	10,6	299,2
Soya Fasülyesi	CORE	4	0	-	%16,45	%15,94	%0,5	1	7	7	288,8
Soya Fasülyesi	CORE	4	1	-	%21,50	%21,74	-0,2%	10	91	9,1	293,8
Soya Fasülyesi	CORE	4	2	-	%11,40	%8,70	%2,7	3	20	6,7	270,6
Soya Fasülyesi	CORE	4	3	-	%21,30	%17,65	%3,7	10	119	11,9	284,6
Soya Fasülyesi	CORE	4	4	-	%32,03	%29,41	%2,6	8	80	10	279,9
Soya Fasülyesi	CORE	4	5	-	%17,40	%13,24	%4,2	4	47	11,8	289,5
Soya Fasülyesi	CORE	4	6	-	%11,54	%10,29	%1,3	2	17	8,5	292,3
Soya Fasülyesi	CORE	4	7	-	%18,05	%17,65	%0,4	6	73	12,2	328,7
Soya Fasülyesi	CORE	4	8	-	%5,69	%5,88	-0,2%	11	85	7,7	280,6
Soya Fasülyesi	CORE	4	9	-	%15,45	%13,24	%2,2	15	157	10,5	313,4
Soya Fasülyesi	CORE	5	0	-	%19,38	%18,84	%0,5	3	18	6	227,2
Soya Fasülyesi	CORE	5	1	-	%18,24	%17,39	%0,8	4	30	7,5	264
Soya Fasülyesi	CORE	5	2	-	%17,43	%18,84	-1,4%	3	24	8	263,3
Soya Fasülyesi	CORE	5	3	-	%28,29	%32,35	-4,1%	7	63	9	250,7
Soya Fasülyesi	CORE	5	4	-	%16,75	%17,65	-0,9%	6	56	9,3	234
Soya Fasülyesi	CORE	5	5	-	%20,49	%20,59	-0,1%	11	109	9,9	274,6
Soya Fasülyesi	CORE	5	6	-	%22,76	%22,06	%0,7	14	168	12	253,7
Soya Fasülyesi	CORE	5	7	-	%18,37	%19,12	-0,7%	3	26	8,7	246,8
Soya Fasülyesi	CORE	5	8	-	%21,63	%20,59	%1	6	52	8,7	280,4
Soya Fasülyesi	CORE	5	9	-	%29,11	%27,94	%1,2	10	114	11,4	261,6
Soya Fasülyesi	HIDER	1	0	-	%91,10	%82,50	%8,6	20	175	8,8	40
Soya Fasülyesi	HIDER	1	1	-	%90,90	%91,10	-0,2%	16	133	8,3	36

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Soya Fasülyesi	HIDER	1	2	-	%90,30	%80,70	%9,6	22	183	8,3	44
Soya Fasülyesi	HIDER	1	3	-	%92,50	%88,90	%3,6	25	225	9	48
Soya Fasülyesi	HIDER	1	4	-	%91,50	%87,30	%4,2	22	195	8,9	46
Soya Fasülyesi	HIDER	1	5	-	%91,30	%81,80	%9,5	21	178	8,5	40
Soya Fasülyesi	HIDER	1	6	-	%89,90	%89,50	%0,4	20	171	8,6	41
Soya Fasülyesi	HIDER	1	7	-	%89,70	%80,40	%9,3	17	174	10,2	36
Soya Fasülyesi	HIDER	1	8	-	%89,50	%79,70	%9,8	19	170	8,9	37
Soya Fasülyesi	HIDER	1	9	-	%91,90	%87,50	%4,4	20	172	8,6	39
Soya Fasülyesi	HIDER	2	0	-	%90,30	%80,70	%9,6	18	168	9,3	40
Soya Fasülyesi	HIDER	2	1	-	%90,30	%89,30	%1	19	166	8,7	36
Soya Fasülyesi	HIDER	2	2	-	%90,30	%78,90	%11,4	24	222	9,3	44
Soya Fasülyesi	HIDER	2	3	-	%92,30	%90,70	%1,6	25	226	9	48
Soya Fasülyesi	HIDER	2	4	-	%91,10	%87,30	%3,8	19	147	7,7	46
Soya Fasülyesi	HIDER	2	5	-	%90,50	%83,60	%6,9	21	193	9,2	40
Soya Fasülyesi	HIDER	2	6	-	%90,90	%87,70	%3,2	20	171	8,6	41
Soya Fasülyesi	HIDER	2	7	-	%90,50	%71,40	%19,1	21	199	9,5	36
Soya Fasülyesi	HIDER	2	8	-	%91,10	%88,10	%3	20	192	9,6	37
Soya Fasülyesi	HIDER	2	9	-	%93,10	%80,40	%12,7	20	188	9,4	39
Soya Fasülyesi	HIDER	3	0	-	%91,10	%86,00	%5,1	19	181	9,5	40
Soya Fasülyesi	HIDER	3	1	-	%90,50	%83,90	%6,6	19	148	7,8	36
Soya Fasülyesi	HIDER	3	2	-	%91,10	%87,70	%3,4	23	215	9,3	44
Soya Fasülyesi	HIDER	3	3	-	%89,40	%96,30	-6,9%	17	148	8,7	48
Soya Fasülyesi	HIDER	3	4	-	%92,10	%89,10	%3	19	160	8,4	46
Soya Fasülyesi	HIDER	3	5	-	%90,30	%87,30	%3	19	153	8,1	40
Soya Fasülyesi	HIDER	3	6	-	%91,30	%89,50	%1,8	21	190	9	41
Soya Fasülyesi	HIDER	3	7	-	%89,70	%82,10	%7,6	16	147	9,2	36
Soya Fasülyesi	HIDER	3	8	-	%90,70	%86,40	%4,3	18	152	8,4	37
Soya Fasülyesi	HIDER	3	9	-	%91,10	%85,70	%5,4	18	162	9	39
Soya Fasülyesi	HIDER	4	0	-	%92,90	%89,50	%3,4	24	206	8,6	40
Soya Fasülyesi	HIDER	4	1	-	%90,10	%85,70	%4,4	17	154	9,1	36
Soya Fasülyesi	HIDER	4	2	-	%90,10	%89,50	%0,6	21	190	9	44
Soya Fasülyesi	HIDER	4	3	-	%90,90	%92,60	-1,7%	21	183	8,7	48
Soya Fasülyesi	HIDER	4	4	-	%90,50	%92,70	-2,2%	20	152	7,6	46
Soya Fasülyesi	HIDER	4	5	-	%91,70	%85,50	%6,2	22	198	9	40
Soya Fasülyesi	HIDER	4	6	-	%91,30	%91,20	%0,1	16	135	8,4	41
Soya Fasülyesi	HIDER	4	7	-	%91,90	%82,10	%9,8	20	188	9,4	36
Soya Fasülyesi	HIDER	4	8	-	%91,70	%83,10	%8,6	19	169	8,9	37
Soya Fasülyesi	HIDER	4	9	-	%90,90	%82,10	%8,8	19	178	9,4	39
Soya Fasülyesi	HIDER	5	0	-	%91,10	%86,00	%5,1	20	180	9	40
Soya Fasülyesi	HIDER	5	1	-	%90,90	%87,50	%3,4	23	202	8,8	36
Soya Fasülyesi	HIDER	5	2	-	%91,30	%84,20	%7,1	23	211	9,2	44
Soya Fasülyesi	HIDER	5	3	-	%91,30	%87,00	%4,3	23	192	8,3	48
Soya Fasülyesi	HIDER	5	4	-	%92,10	%89,10	%3	22	180	8,2	46
Soya Fasülyesi	HIDER	5	5	-	%91,50	%89,10	%2,4	22	176	8	40
Soya Fasülyesi	HIDER	5	6	-	%90,30	%89,50	%0,8	18	146	8,1	41
Soya Fasülyesi	HIDER	5	7	-	%91,70	%76,80	%14,9	19	179	9,4	36
Soya Fasülyesi	HIDER	5	8	-	%91,10	%83,10	%8	19	171	9	37
Soya Fasülyesi	HIDER	5	9	-	%91,70	%87,50	%4,2	17	147	8,6	39
Soya Fasülyesi	LDWPSO	1	0	320.193	%68,08	%65,22	%2,9	17	39	2,3	9.857,5
Soya Fasülyesi	LDWPSO	1	1	320.162	%66,45	%69,57	-3,1%	17	42	2,5	10.458,2
Soya Fasülyesi	LDWPSO	1	2	320.192	%65,80	%73,91	-8,1%	17	41	2,4	10.499,2
Soya Fasülyesi	LDWPSO	1	3	300.448	%51,71	%52,94	-1,2%	15	47	3,1	10.117,1
Soya Fasülyesi	LDWPSO	1	4	340.276	%66,34	%67,65	-1,3%	18	49	2,7	10.548,9
Soya Fasülyesi	LDWPSO	1	5	320.336	%59,19	%57,35	%1,8	16	45	2,8	10.418,8
Soya Fasülyesi	LDWPSO	1	6	320.200	%53,50	%51,47	%2	17	45	2,6	10.425,2
Soya Fasülyesi	LDWPSO	1	7	320.162	%60,98	%61,76	-0,8%	17	37	2,2	10.135,9
Soya Fasülyesi	LDWPSO	1	8	320.172	%62,44	%57,35	%5,1	17	44	2,6	9.986,2
Soya Fasülyesi	LDWPSO	1	9	320.176	%61,95	%55,88	%6,1	17	45	2,6	10.503,6
Soya Fasülyesi	LDWPSO	2	0	320.138	%56,84	%56,52	%0,3	17	39	2,3	12.113,8
Soya Fasülyesi	LDWPSO	2	1	320.320	%67,75	%68,12	-0,4%	17	50	2,9	10.168,4
Soya Fasülyesi	LDWPSO	2	2	340.169	%56,19	%57,97	-1,8%	18	43	2,4	11.773,2
Soya Fasülyesi	LDWPSO	2	3	320.325	%67,97	%75,00	-7,0%	17	47	2,8	10.209,3
Soya Fasülyesi	LDWPSO	2	4	340.206	%72,03	%73,53	-1,5%	16	40	2,5	11.173,4
Soya Fasülyesi	LDWPSO	2	5	320.210	%47,97	%45,59	%2,4	17	45	2,6	10.700,6
Soya Fasülyesi	LDWPSO	2	6	320.268	%66,34	%58,82	%7,5	17	49	2,9	10.267,1
Soya Fasülyesi	LDWPSO	2	7	340.184	%52,85	%50,00	%2,8	18	48	2,7	12.234,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Soya Fasülyesi	LDWPSO	2	8	340.181	%59,19	%54,41	%4,8	18	44	2,4	11.167,2
Soya Fasülyesi	LDWPSO	2	9	340.458	%63,58	%58,82	%4,8	18	57	3,2	11.424,1
Soya Fasülyesi	LDWPSO	3	0	340.230	%69,38	%65,22	%4,2	18	49	2,7	10.347,7
Soya Fasülyesi	LDWPSO	3	1	320.396	%69,87	%71,01	-1,1%	17	47	2,8	10.098,3
Soya Fasülyesi	LDWPSO	3	2	320.342	%78,01	%78,26	-0,2%	17	46	2,7	9.404,7
Soya Fasülyesi	LDWPSO	3	3	320.342	%72,85	%80,88	-8,0%	17	46	2,7	10.258,6
Soya Fasülyesi	LDWPSO	3	4	320.264	%75,61	%77,94	-2,3%	17	43	2,5	10.152,2
Soya Fasülyesi	LDWPSO	3	5	320.230	%77,40	%77,94	-0,5%	17	44	2,6	10.200,5
Soya Fasülyesi	LDWPSO	3	6	320.244	%76,75	%70,59	%6,2	17	41	2,4	9.567,9
Soya Fasülyesi	LDWPSO	3	7	320.264	%75,77	%69,12	%6,7	17	45	2,6	10.196,5
Soya Fasülyesi	LDWPSO	3	8	320.246	%69,11	%63,24	%5,9	17	43	2,5	9.862
Soya Fasülyesi	LDWPSO	3	9	340.308	%70,57	%72,06	-1,5%	18	49	2,7	10.139,6
Soya Fasülyesi	LDWPSO	4	0	340.220	%68,24	%63,77	%4,5	18	48	2,7	10.431,2
Soya Fasülyesi	LDWPSO	4	1	300.223	%62,70	%60,87	%1,8	16	40	2,5	9.594,5
Soya Fasülyesi	LDWPSO	4	2	320.234	%72,31	%65,22	%7,1	17	40	2,4	9.669,5
Soya Fasülyesi	LDWPSO	4	3	320.204	%62,76	%73,53	-10,8%	17	42	2,5	9.963,2
Soya Fasülyesi	LDWPSO	4	4	320.155	%71,22	%70,59	%0,6	17	37	2,2	10.127,2
Soya Fasülyesi	LDWPSO	4	5	320.262	%69,27	%72,06	-2,8%	17	44	2,6	10.114,8
Soya Fasülyesi	LDWPSO	4	6	320.167	%69,59	%72,06	-2,5%	17	38	2,2	9.804,3
Soya Fasülyesi	LDWPSO	4	7	320.170	%73,33	%66,18	%7,2	17	38	2,2	9.487,9
Soya Fasülyesi	LDWPSO	4	8	320.280	%65,85	%63,24	%2,6	17	45	2,6	9.855,6
Soya Fasülyesi	LDWPSO	4	9	340.292	%68,13	%63,24	%4,9	18	50	2,8	10.615,1
Soya Fasülyesi	LDWPSO	5	0	320.158	%64,01	%57,97	%6	17	40	2,4	9.715,1
Soya Fasülyesi	LDWPSO	5	1	320.164	%64,98	%63,77	%1,2	17	41	2,4	9.498
Soya Fasülyesi	LDWPSO	5	2	320.258	%68,08	%73,91	-5,8%	17	43	2,5	9.812,5
Soya Fasülyesi	LDWPSO	5	3	320.198	%64,07	%70,59	-6,5%	17	43	2,5	9.276,9
Soya Fasülyesi	LDWPSO	5	4	320.171	%66,34	%70,59	-4,2%	16	35	2,2	8.836,2
Soya Fasülyesi	LDWPSO	5	5	320.236	%64,39	%64,71	-0,3%	17	42	2,5	8.148,4
Soya Fasülyesi	LDWPSO	5	6	320.175	%68,94	%66,18	%2,8	17	41	2,4	8.597,7
Soya Fasülyesi	LDWPSO	5	7	300.200	%63,25	%57,35	%5,9	16	41	2,6	7.822,5
Soya Fasülyesi	LDWPSO	5	8	340.186	%64,07	%61,76	%2,3	18	49	2,7	8.204,9
Soya Fasülyesi	LDWPSO	5	9	340.161	%67,64	%69,12	-1,5%	18	43	2,4	7.981
Soya Fasülyesi	PGIRLA	1	0	-	%54,65	%54,39	%0,3	20	405	20,3	4
Soya Fasülyesi	PGIRLA	1	1	-	%50,40	%51,79	-1,4%	20	394	19,7	5
Soya Fasülyesi	PGIRLA	1	2	-	%52,48	%52,63	-0,2%	20	389	19,5	4
Soya Fasülyesi	PGIRLA	1	3	-	%49,02	%57,41	-8,4%	20	422	21,1	5
Soya Fasülyesi	PGIRLA	1	4	-	%55,23	%50,91	%4,3	20	406	20,3	5
Soya Fasülyesi	PGIRLA	1	5	-	%50,30	%56,36	-6,1%	20	415	20,8	5
Soya Fasülyesi	PGIRLA	1	6	-	%45,35	%40,35	%5	20	398	19,9	4
Soya Fasülyesi	PGIRLA	1	7	-	%46,25	%37,50	%8,7	20	382	19,1	5
Soya Fasülyesi	PGIRLA	1	8	-	%53,48	%50,85	%2,6	20	407	20,4	4
Soya Fasülyesi	PGIRLA	1	9	-	%50,40	%51,79	-1,4%	20	398	19,9	5
Soya Fasülyesi	PGIRLA	2	0	-	%55,05	%47,37	%7,7	20	392	19,6	4
Soya Fasülyesi	PGIRLA	2	1	-	%53,36	%58,93	-5,6%	20	422	21,1	5
Soya Fasülyesi	PGIRLA	2	2	-	%56,83	%59,65	-2,8%	20	382	19,1	4
Soya Fasülyesi	PGIRLA	2	3	-	%52,17	%57,41	-5,2%	20	406	20,3	5
Soya Fasülyesi	PGIRLA	2	4	-	%45,96	%47,27	-1,3%	20	423	21,2	5
Soya Fasülyesi	PGIRLA	2	5	-	%55,42	%49,09	%6,3	20	413	20,7	5
Soya Fasülyesi	PGIRLA	2	6	-	%56,83	%54,39	%2,4	20	382	19,1	4
Soya Fasülyesi	PGIRLA	2	7	-	%57,31	%55,36	%2	20	411	20,6	5
Soya Fasülyesi	PGIRLA	2	8	-	%54,08	%52,54	%1,5	20	392	19,6	4
Soya Fasülyesi	PGIRLA	2	9	-	%55,73	%51,79	%3,9	20	406	20,3	5
Soya Fasülyesi	PGIRLA	3	0	-	%56,83	%56,14	%0,7	20	452	22,6	4
Soya Fasülyesi	PGIRLA	3	1	-	%57,11	%58,93	-1,8%	20	428	21,4	5
Soya Fasülyesi	PGIRLA	3	2	-	%57,23	%56,14	%1,1	20	419	21	4
Soya Fasülyesi	PGIRLA	3	3	-	%54,53	%50,00	%4,5	20	394	19,7	5
Soya Fasülyesi	PGIRLA	3	4	-	%55,82	%52,73	%3,1	20	418	20,9	5
Soya Fasülyesi	PGIRLA	3	5	-	%57,00	%52,73	%4,3	20	410	20,5	5
Soya Fasülyesi	PGIRLA	3	6	-	%55,84	%57,89	-2,1%	20	423	21,2	4
Soya Fasülyesi	PGIRLA	3	7	-	%54,35	%51,79	%2,6	20	420	21	5
Soya Fasülyesi	PGIRLA	3	8	-	%58,05	%50,85	%7,2	20	397	19,9	4
Soya Fasülyesi	PGIRLA	3	9	-	%54,94	%50,00	%4,9	20	429	21,5	5
Soya Fasülyesi	PGIRLA	4	0	-	%54,06	%54,39	-0,3%	20	417	20,9	4
Soya Fasülyesi	PGIRLA	4	1	-	%48,22	%48,21	%0	20	419	21	5
Soya Fasülyesi	PGIRLA	4	2	-	%51,49	%49,12	%2,4	20	403	20,2	4
Soya Fasülyesi	PGIRLA	4	3	-	%48,43	%51,85	-3,4%	20	424	21,2	5

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Soya Fasülyesi	PGIRLA	4	4	-	%56,21	%56,36	-0,2%	20	416	20,8	5
Soya Fasülyesi	PGIRLA	4	5	-	%49,51	%41,82	%7,7	20	400	20	5
Soya Fasülyesi	PGIRLA	4	6	-	%52,67	%52,63	%0	20	419	21	4
Soya Fasülyesi	PGIRLA	4	7	-	%52,57	%51,79	%0,8	20	404	20,2	5
Soya Fasülyesi	PGIRLA	4	8	-	%50,70	%49,15	%1,5	20	404	20,2	4
Soya Fasülyesi	PGIRLA	4	9	-	%48,22	%41,07	%7,1	20	416	20,8	5
Soya Fasülyesi	PGIRLA	5	0	-	%53,27	%50,88	%2,4	20	420	21	4
Soya Fasülyesi	PGIRLA	5	1	-	%53,56	%53,57	%0	20	411	20,6	5
Soya Fasülyesi	PGIRLA	5	2	-	%51,09	%49,12	%2	20	402	20,1	4
Soya Fasülyesi	PGIRLA	5	3	-	%53,35	%48,15	%5,2	20	390	19,5	5
Soya Fasülyesi	PGIRLA	5	4	-	%56,41	%54,55	%1,9	20	418	20,9	5
Soya Fasülyesi	PGIRLA	5	5	-	%48,72	%49,09	-0,4%	20	406	20,3	5
Soya Fasülyesi	PGIRLA	5	6	-	%49,50	%47,37	%2,1	20	416	20,8	4
Soya Fasülyesi	PGIRLA	5	7	-	%50,00	%41,07	%8,9	20	421	21,1	5
Soya Fasülyesi	PGIRLA	5	8	-	%49,11	%47,46	%1,6	20	408	20,4	4
Soya Fasülyesi	PGIRLA	5	9	-	%56,52	%57,14	-0,6%	20	416	20,8	5
Soya Fasülyesi	SIA	1	0	-	%98,37	%89,86	%8,5	81	756	9,3	20
Soya Fasülyesi	SIA	1	1	-	%99,67	%95,65	%4	90	830	9,2	21
Soya Fasülyesi	SIA	1	2	-	%98,53	%89,86	%8,7	75	708	9,4	19
Soya Fasülyesi	SIA	1	3	-	%97,40	%91,18	%6,2	87	725	8,3	20
Soya Fasülyesi	SIA	1	4	-	%98,37	%94,12	%4,3	76	803	10,6	19
Soya Fasülyesi	SIA	1	5	-	%97,72	%92,65	%5,1	85	852	10	20
Soya Fasülyesi	SIA	1	6	-	%97,40	%86,76	%10,6	83	810	9,8	20
Soya Fasülyesi	SIA	1	7	-	%97,56	%88,24	%9,3	77	820	10,6	18
Soya Fasülyesi	SIA	1	8	-	%99,02	%88,24	%10,8	92	865	9,4	23
Soya Fasülyesi	SIA	1	9	-	%97,72	%83,82	%13,9	80	849	10,6	22
Soya Fasülyesi	SIA	2	0	-	%99,19	%92,75	%6,4	86	654	7,6	18
Soya Fasülyesi	SIA	2	1	-	%99,67	%89,86	%9,8	91	704	7,7	20
Soya Fasülyesi	SIA	2	2	-	%98,21	%89,86	%8,4	79	786	9,9	17
Soya Fasülyesi	SIA	2	3	-	%97,72	%97,06	%0,7	91	773	8,5	22
Soya Fasülyesi	SIA	2	4	-	%98,37	%86,76	%11,6	85	666	7,8	20
Soya Fasülyesi	SIA	2	5	-	%98,86	%92,65	%6,2	87	783	9	22
Soya Fasülyesi	SIA	2	6	-	%99,02	%91,18	%7,8	91	861	9,5	25
Soya Fasülyesi	SIA	2	7	-	%98,86	%88,24	%10,6	81	823	10,2	21
Soya Fasülyesi	SIA	2	8	-	%98,21	%92,65	%5,6	85	684	8	19
Soya Fasülyesi	SIA	2	9	-	%99,02	%86,76	%12,3	81	756	9,3	17
Soya Fasülyesi	SIA	3	0	-	%98,37	%89,86	%8,5	79	651	8,2	17
Soya Fasülyesi	SIA	3	1	-	%99,67	%91,30	%8,4	87	740	8,5	18
Soya Fasülyesi	SIA	3	2	-	%98,86	%94,20	%4,7	92	683	7,4	23
Soya Fasülyesi	SIA	3	3	-	%98,70	%94,12	%4,6	87	749	8,6	21
Soya Fasülyesi	SIA	3	4	-	%98,70	%91,18	%7,5	83	712	8,6	16
Soya Fasülyesi	SIA	3	5	-	%98,70	%91,18	%7,5	87	746	8,6	18
Soya Fasülyesi	SIA	3	6	-	%98,86	%89,71	%9,2	87	839	9,6	20
Soya Fasülyesi	SIA	3	7	-	%97,72	%91,18	%6,5	80	760	9,5	16
Soya Fasülyesi	SIA	3	8	-	%98,05	%89,71	%8,3	83	769	9,3	21
Soya Fasülyesi	SIA	3	9	-	%99,51	%91,18	%8,3	79	787	10	18
Soya Fasülyesi	SIA	4	0	-	%97,72	%86,96	%10,8	77	705	9,2	17
Soya Fasülyesi	SIA	4	1	-	%99,67	%95,65	%4	92	802	8,7	22
Soya Fasülyesi	SIA	4	2	-	%98,86	%85,51	%13,4	82	792	9,7	19
Soya Fasülyesi	SIA	4	3	-	%98,37	%94,12	%4,3	78	665	8,5	17
Soya Fasülyesi	SIA	4	4	-	%98,21	%91,18	%7	89	756	8,5	21
Soya Fasülyesi	SIA	4	5	-	%98,21	%91,18	%7	84	702	8,4	20
Soya Fasülyesi	SIA	4	6	-	%97,72	%91,18	%6,5	79	697	8,8	17
Soya Fasülyesi	SIA	4	7	-	%99,02	%89,71	%9,3	82	750	9,1	17
Soya Fasülyesi	SIA	4	8	-	%98,54	%88,24	%10,3	83	759	9,1	21
Soya Fasülyesi	SIA	4	9	-	%99,51	%88,24	%11,3	81	795	9,8	16
Soya Fasülyesi	SIA	5	0	-	%97,07	%88,41	%8,7	84	818	9,7	22
Soya Fasülyesi	SIA	5	1	-	%99,67	%92,75	%6,9	95	725	7,6	18
Soya Fasülyesi	SIA	5	2	-	%98,05	%89,86	%8,2	76	761	10	17
Soya Fasülyesi	SIA	5	3	-	%97,89	%92,65	%5,2	83	741	8,9	22
Soya Fasülyesi	SIA	5	4	-	%99,02	%89,71	%9,3	88	712	8,1	22
Soya Fasülyesi	SIA	5	5	-	%97,24	%89,71	%7,5	82	752	9,2	19
Soya Fasülyesi	SIA	5	6	-	%98,37	%88,24	%10,1	85	726	8,5	20
Soya Fasülyesi	SIA	5	7	-	%98,05	%85,29	%12,8	86	719	8,4	19
Soya Fasülyesi	SIA	5	8	-	%97,24	%91,18	%6,1	79	705	8,9	18
Soya Fasülyesi	SIA	5	9	-	%99,02	%85,29	%13,7	84	746	8,9	20

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Süsen Çiçeği	ABCMiner	1	0	40.560	%97,78	%86,67	%11,1	3	3	1	2,8
Süsen Çiçeği	ABCMiner	1	1	40.532	%98,52	%86,67	%11,9	3	3	1	3,2
Süsen Çiçeği	ABCMiner	1	2	40.523	%97,78	%93,33	%4,4	3	3	1	3,2
Süsen Çiçeği	ABCMiner	1	3	40.494	%97,78	%100	-2,2%	3	3	1	3,1
Süsen Çiçeği	ABCMiner	1	4	40.495	%97,78	%93,33	%4,4	3	3	1	3,1
Süsen Çiçeği	ABCMiner	1	5	40.593	%98,52	%93,33	%5,2	3	3	1	3
Süsen Çiçeği	ABCMiner	1	6	40.344	%98,52	%93,33	%5,2	3	3	1	3,4
Süsen Çiçeği	ABCMiner	1	7	40.470	%97,78	%86,67	%11,1	3	3	1	2,9
Süsen Çiçeği	ABCMiner	1	8	40.570	%97,78	%93,33	%4,4	3	3	1	2,8
Süsen Çiçeği	ABCMiner	1	9	40.654	%97,78	%86,67	%11,1	3	4	1,3	2,8
Süsen Çiçeği	ABCMiner	2	0	40.456	%97,78	%93,33	%4,4	3	3	1	3
Süsen Çiçeği	ABCMiner	2	1	40.709	%98,52	%93,33	%5,2	3	3	1	3,1
Süsen Çiçeği	ABCMiner	2	2	40.368	%97,78	%93,33	%4,4	3	3	1	3,3
Süsen Çiçeği	ABCMiner	2	3	40.398	%97,78	%100	-2,2%	3	3	1	2,9
Süsen Çiçeği	ABCMiner	2	4	40.397	%97,78	%100	-2,2%	3	3	1	3,1
Süsen Çiçeği	ABCMiner	2	5	40.392	%98,52	%93,33	%5,2	3	3	1	3,2
Süsen Çiçeği	ABCMiner	2	6	40.457	%98,52	%93,33	%5,2	3	3	1	3,3
Süsen Çiçeği	ABCMiner	2	7	40.402	%97,78	%86,67	%11,1	3	3	1	2,8
Süsen Çiçeği	ABCMiner	2	8	40.450	%97,78	%93,33	%4,4	3	3	1	2,8
Süsen Çiçeği	ABCMiner	2	9	40.390	%97,78	%93,33	%4,4	3	4	1,3	2,8
Süsen Çiçeği	ABCMiner	3	0	40.513	%97,78	%93,33	%4,4	3	3	1	3,1
Süsen Çiçeği	ABCMiner	3	1	40.507	%98,52	%93,33	%5,2	3	3	1	3,1
Süsen Çiçeği	ABCMiner	3	2	40.507	%97,78	%93,33	%4,4	3	3	1	3,3
Süsen Çiçeği	ABCMiner	3	3	40.516	%97,78	%100	-2,2%	3	3	1	3,2
Süsen Çiçeği	ABCMiner	3	4	40.518	%97,78	%100	-2,2%	3	3	1	3,1
Süsen Çiçeği	ABCMiner	3	5	40.515	%98,52	%93,33	%5,2	3	3	1	3,4
Süsen Çiçeği	ABCMiner	3	6	40.483	%98,52	%93,33	%5,2	3	3	1	2,8
Süsen Çiçeği	ABCMiner	3	7	40.508	%97,78	%86,67	%11,1	3	3	1	2,8
Süsen Çiçeği	ABCMiner	3	8	40.500	%97,78	%93,33	%4,4	3	3	1	2,8
Süsen Çiçeği	ABCMiner	3	9	40.519	%97,78	%93,33	%4,4	3	4	1,3	2,7
Süsen Çiçeği	ABCMiner	4	0	40.293	%97,78	%93,33	%4,4	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	1	40.290	%98,52	%93,33	%5,2	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	2	40.293	%97,78	%93,33	%4,4	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	3	40.295	%97,78	%100	-2,2%	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	4	40.295	%97,78	%100	-2,2%	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	5	40.284	%98,52	%93,33	%5,2	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	6	40.284	%98,52	%93,33	%5,2	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	7	60.432	%97,78	%73,33	%24,4	3	3	1	3
Süsen Çiçeği	ABCMiner	4	8	40.293	%97,78	%93,33	%4,4	3	3	1	2,7
Süsen Çiçeği	ABCMiner	4	9	40.292	%97,78	%93,33	%4,4	3	4	1,3	2,7
Süsen Çiçeği	ABCMiner	5	0	40.541	%97,78	%93,33	%4,4	3	3	1	2,5
Süsen Çiçeği	ABCMiner	5	1	40.653	%98,52	%93,33	%5,2	3	3	1	2,6
Süsen Çiçeği	ABCMiner	5	2	40.474	%97,78	%86,67	%11,1	3	4	1,3	2,6
Süsen Çiçeği	ABCMiner	5	3	40.535	%97,78	%100	-2,2%	3	3	1	2,7
Süsen Çiçeği	ABCMiner	5	4	40.468	%97,78	%86,67	%11,1	3	3	1	2,8
Süsen Çiçeği	ABCMiner	5	5	40.626	%98,52	%93,33	%5,2	3	3	1	2,7
Süsen Çiçeği	ABCMiner	5	6	40.535	%98,52	%93,33	%5,2	3	3	1	2,8
Süsen Çiçeği	ABCMiner	5	7	60.711	%97,78	%93,33	%4,4	3	3	1	3,1
Süsen Çiçeği	ABCMiner	5	8	40.529	%97,78	%93,33	%4,4	3	3	1	2,8
Süsen Çiçeği	ABCMiner	5	9	40.534	%97,78	%86,67	%11,1	3	4	1,3	2,7
Süsen Çiçeği	C4.5	-	1	-	%97,78	%86,67	%11,1	4	3	0,8	0,2
Süsen Çiçeği	C4.5	-	2	-	%98,52	%93,33	%5,2	4	3	0,8	0,2
Süsen Çiçeği	C4.5	-	3	-	%97,04	%100	-3,0%	4	2	0,5	0,2
Süsen Çiçeği	C4.5	-	4	-	%97,04	%100	-3,0%	4	2	0,5	0,2
Süsen Çiçeği	C4.5	-	5	-	%97,04	%100	-3,0%	4	2	0,5	0,2
Süsen Çiçeği	C4.5	-	6	-	%97,78	%93,33	%4,4	4	3	0,8	0,2
Süsen Çiçeği	C4.5	-	7	-	%97,78	%93,33	%4,4	4	3	0,8	0,2
Süsen Çiçeği	C4.5	-	8	-	%97,04	%100	-3,0%	4	3	0,8	0,2
Süsen Çiçeği	C4.5	-	9	-	%97,04	%100	-3,0%	4	3	0,8	0,2
Süsen Çiçeği	C4.5	-	10	-	%97,04	%100	-3,0%	4	3	0,8	0,2
Süsen Çiçeği	CoABCMiner	1	0	110.699	%97,04	%93,33	%3,7	5	8	1,6	0,8
Süsen Çiçeği	CoABCMiner	1	1	110.709	%97,04	%93,33	%3,7	4	7	1,8	0,8
Süsen Çiçeği	CoABCMiner	1	2	110.703	%97,78	%100	-2,2%	6	13	2,2	0,8
Süsen Çiçeği	CoABCMiner	1	3	110.706	%97,04	%93,33	%3,7	5	9	1,8	0,9
Süsen Çiçeği	CoABCMiner	1	4	110.715	%97,78	%93,33	%4,4	6	14	2,3	0,8
Süsen Çiçeği	CoABCMiner	1	5	110.721	%96,30	%100	-3,7%	5	8	1,6	0,8

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Süsen Çiçeği	CoABCMiner	1	6	110.717	%97,04	%93,33	%3,7	4	6	1,5	0,8
Süsen Çiçeği	CoABCMiner	1	7	110.724	%96,30	%100	-3,7%	5	9	1,8	0,9
Süsen Çiçeği	CoABCMiner	1	8	110.699	%96,30	%93,33	%3	5	8	1,6	0,8
Süsen Çiçeği	CoABCMiner	1	9	110.713	%96,30	%93,33	%3	4	8	2	0,8
Süsen Çiçeği	CoABCMiner	2	0	110.722	%97,04	%93,33	%3,7	5	8	1,6	0,8
Süsen Çiçeği	CoABCMiner	2	1	110.708	%98,52	%86,67	%11,9	5	9	1,8	0,8
Süsen Çiçeği	CoABCMiner	2	2	110.704	%97,78	%100	-2,2%	5	8	1,6	0,8
Süsen Çiçeği	CoABCMiner	2	3	110.709	%97,04	%93,33	%3,7	5	8	1,6	0,8
Süsen Çiçeği	CoABCMiner	2	4	110.702	%97,78	%100	-2,2%	4	8	2	0,8
Süsen Çiçeği	CoABCMiner	2	5	110.706	%96,30	%93,33	%3	4	5	1,3	0,8
Süsen Çiçeği	CoABCMiner	2	6	110.698	%97,04	%93,33	%3,7	4	6	1,5	0,8
Süsen Çiçeği	CoABCMiner	2	7	110.718	%96,30	%100	-3,7%	5	7	1,4	0,8
Süsen Çiçeği	CoABCMiner	2	8	110.710	%96,30	%100	-3,7%	4	8	2	0,8
Süsen Çiçeği	CoABCMiner	2	9	110.698	%97,04	%93,33	%3,7	6	15	2,5	0,8
Süsen Çiçeği	CoABCMiner	3	0	110.723	%97,78	%100	-2,2%	6	11	1,8	0,9
Süsen Çiçeği	CoABCMiner	3	1	110.700	%97,04	%93,33	%3,7	4	6	1,5	0,9
Süsen Çiçeği	CoABCMiner	3	2	110.708	%97,78	%100	-2,2%	5	10	2	0,8
Süsen Çiçeği	CoABCMiner	3	3	110.678	%97,78	%100	-2,2%	6	10	1,7	0,9
Süsen Çiçeği	CoABCMiner	3	4	110.708	%97,78	%100	-2,2%	5	9	1,8	0,9
Süsen Çiçeği	CoABCMiner	3	5	110.698	%97,04	%93,33	%3,7	5	9	1,8	0,9
Süsen Çiçeği	CoABCMiner	3	6	110.708	%97,04	%93,33	%3,7	4	6	1,5	0,9
Süsen Çiçeği	CoABCMiner	3	7	110.699	%96,30	%100	-3,7%	4	7	1,8	0,9
Süsen Çiçeği	CoABCMiner	3	8	110.699	%97,78	%100	-2,2%	5	12	2,4	1
Süsen Çiçeği	CoABCMiner	3	9	110.720	%96,30	%100	-3,7%	5	8	1,6	0,9
Süsen Çiçeği	CoABCMiner	4	0	110.712	%97,04	%93,33	%3,7	5	8	1,6	0,9
Süsen Çiçeği	CoABCMiner	4	1	110.715	%98,52	%93,33	%5,2	5	8	1,6	0,9
Süsen Çiçeği	CoABCMiner	4	2	110.707	%97,04	%100	-3,0%	6	12	2	1
Süsen Çiçeği	CoABCMiner	4	3	110.717	%97,04	%93,33	%3,7	5	7	1,4	0,9
Süsen Çiçeği	CoABCMiner	4	4	110.709	%97,78	%93,33	%4,4	5	11	2,2	0,9
Süsen Çiçeği	CoABCMiner	4	5	110.718	%96,30	%100	-3,7%	5	7	1,4	0,8
Süsen Çiçeği	CoABCMiner	4	6	110.725	%97,04	%93,33	%3,7	4	6	1,5	0,8
Süsen Çiçeği	CoABCMiner	4	7	110.703	%96,30	%100	-3,7%	5	7	1,4	0,9
Süsen Çiçeği	CoABCMiner	4	8	110.697	%97,04	%100	-3,0%	6	10	1,7	0,9
Süsen Çiçeği	CoABCMiner	4	9	110.721	%96,30	%100	-3,7%	5	8	1,6	0,9
Süsen Çiçeği	CoABCMiner	5	0	110.719	%97,78	%93,33	%4,4	6	10	1,7	1
Süsen Çiçeği	CoABCMiner	5	1	110.719	%97,04	%93,33	%3,7	5	7	1,4	0,8
Süsen Çiçeği	CoABCMiner	5	2	110.703	%97,78	%100	-2,2%	5	11	2,2	0,9
Süsen Çiçeği	CoABCMiner	5	3	110.696	%97,04	%93,33	%3,7	4	7	1,8	0,9
Süsen Çiçeği	CoABCMiner	5	4	110.713	%97,78	%93,33	%4,4	6	10	1,7	0,9
Süsen Çiçeği	CoABCMiner	5	5	110.705	%96,30	%100	-3,7%	4	8	2	0,8
Süsen Çiçeği	CoABCMiner	5	6	110.702	%97,04	%93,33	%3,7	4	6	1,5	0,9
Süsen Çiçeği	CoABCMiner	5	7	110.714	%96,30	%100	-3,7%	4	6	1,5	0,9
Süsen Çiçeği	CoABCMiner	5	8	110.717	%96,30	%100	-3,7%	4	6	1,5	0,9
Süsen Çiçeği	CoABCMiner	5	9	110.692	%96,30	%93,33	%3	5	8	1,6	0,8
Süsen Çiçeği	CORE	1	0	1.964.909	%98,52	%93,33	%5,2	5	9	1,8	22,3
Süsen Çiçeği	CORE	1	1	1.965.684	%98,52	%93,33	%5,2	4	7	1,8	22,5
Süsen Çiçeği	CORE	1	2	1.964.457	%97,78	%100	-2,2%	4	8	2	24
Süsen Çiçeği	CORE	1	3	1.964.874	%98,52	%86,67	%11,9	5	7	1,4	21,7
Süsen Çiçeği	CORE	1	4	1.963.217	%97,78	%100	-2,2%	4	5	1,3	22,6
Süsen Çiçeği	CORE	1	5	1.964.166	%98,52	%93,33	%5,2	4	6	1,5	21,9
Süsen Çiçeği	CORE	1	6	1.965.257	%98,52	%93,33	%5,2	7	14	2	21,7
Süsen Çiçeği	CORE	1	7	1.964.346	%97,78	%100	-2,2%	4	5	1,3	22,3
Süsen Çiçeği	CORE	1	8	1.962.737	%97,04	%100	-3,0%	4	6	1,5	22,9
Süsen Çiçeği	CORE	1	9	1.965.470	%97,78	%100	-2,2%	4	6	1,5	21,9
Süsen Çiçeği	CORE	2	0	-	%97,78	%86,67	%11,1	3	4	1,3	21
Süsen Çiçeği	CORE	2	1	-	%97,78	%93,33	%4,4	4	6	1,5	22,2
Süsen Çiçeği	CORE	2	2	-	%98,52	%93,33	%5,2	6	12	2	23,1
Süsen Çiçeği	CORE	2	3	-	%98,52	%93,33	%5,2	4	8	2	22
Süsen Çiçeği	CORE	2	4	-	%97,78	%93,33	%4,4	4	5	1,3	21,7
Süsen Çiçeği	CORE	2	5	-	%98,52	%93,33	%5,2	4	6	1,5	22,2
Süsen Çiçeği	CORE	2	6	-	%98,52	%93,33	%5,2	4	7	1,8	22
Süsen Çiçeği	CORE	2	7	-	%97,78	%100	-2,2%	4	6	1,5	22,3
Süsen Çiçeği	CORE	2	8	-	%97,78	%100	-2,2%	4	5	1,3	22,4
Süsen Çiçeği	CORE	2	9	-	%97,78	%100	-2,2%	4	6	1,5	21,5
Süsen Çiçeği	CORE	3	0	-	%98,52	%86,67	%11,9	5	10	2	21,9
Süsen Çiçeği	CORE	3	1	-	%97,04	%80,00	%17	3	6	2	22,7

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Süsen Çiçeği	CORE	3	2	-	%97,78	%100	-2,2%	4	11	2,8	23,7
Süsen Çiçeği	CORE	3	3	-	%98,52	%86,67	%11,9	5	8	1,6	22
Süsen Çiçeği	CORE	3	4	-	%97,78	%100	-2,2%	4	4	1	21,4
Süsen Çiçeği	CORE	3	5	-	%97,78	%93,33	%4,4	7	13	1,9	22,8
Süsen Çiçeği	CORE	3	6	-	%98,52	%93,33	%5,2	4	6	1,5	21
Süsen Çiçeği	CORE	3	7	-	%97,78	%100	-2,2%	4	7	1,8	21,2
Süsen Çiçeği	CORE	3	8	-	%97,78	%100	-2,2%	4	7	1,8	20,8
Süsen Çiçeği	CORE	3	9	-	%98,52	%100	-1,5%	6	10	1,7	21,6
Süsen Çiçeği	CORE	4	0	-	%97,78	%93,33	%4,4	4	8	2	21,9
Süsen Çiçeği	CORE	4	1	-	%98,52	%86,67	%11,9	4	6	1,5	22,8
Süsen Çiçeği	CORE	4	2	-	%97,78	%100	-2,2%	4	6	1,5	23,6
Süsen Çiçeği	CORE	4	3	-	%97,78	%100	-2,2%	4	7	1,8	22,4
Süsen Çiçeği	CORE	4	4	-	%97,78	%93,33	%4,4	5	9	1,8	22
Süsen Çiçeği	CORE	4	5	-	%98,52	%93,33	%5,2	4	6	1,5	22,5
Süsen Çiçeği	CORE	4	6	-	%98,52	%93,33	%5,2	4	6	1,5	22,3
Süsen Çiçeği	CORE	4	7	-	%97,78	%100	-2,2%	4	5	1,3	22,1
Süsen Çiçeği	CORE	4	8	-	%97,78	%100	-2,2%	7	8	1,1	21,8
Süsen Çiçeği	CORE	4	9	-	%97,04	%100	-3,0%	3	5	1,7	21,2
Süsen Çiçeği	CORE	5	0	-	%97,78	%93,33	%4,4	4	6	1,5	21,7
Süsen Çiçeği	CORE	5	1	-	%98,52	%93,33	%5,2	4	6	1,5	21,6
Süsen Çiçeği	CORE	5	2	-	%97,04	%100	-3,0%	4	7	1,8	23,1
Süsen Çiçeği	CORE	5	3	-	%99,26	%93,33	%5,9	13	19	1,5	22,9
Süsen Çiçeği	CORE	5	4	-	%98,52	%93,33	%5,2	7	11	1,6	22,5
Süsen Çiçeği	CORE	5	5	-	%98,52	%93,33	%5,2	4	7	1,8	22,5
Süsen Çiçeği	CORE	5	6	-	%98,52	%93,33	%5,2	4	6	1,5	20,9
Süsen Çiçeği	CORE	5	7	-	%97,78	%100	-2,2%	4	7	1,8	21,6
Süsen Çiçeği	CORE	5	8	-	%97,78	%100	-2,2%	4	7	1,8	21,9
Süsen Çiçeği	CORE	5	9	-	%97,78	%100	-2,2%	4	8	2	21,7
Süsen Çiçeği	HIDER	1	0	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	1	1	-	%97,00	%93,30	%3,7	3	6	2	1
Süsen Çiçeği	HIDER	1	2	-	%97,00	%93,30	%3,7	3	7	2,3	2
Süsen Çiçeği	HIDER	1	3	-	%97,80	%93,30	%4,5	3	4	1,3	1
Süsen Çiçeği	HIDER	1	4	-	%97,80	%100	-2,2%	3	7	2,3	2
Süsen Çiçeği	HIDER	1	5	-	%97,00	%93,30	%3,7	3	8	2,7	1
Süsen Çiçeği	HIDER	1	6	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	1	7	-	%97,00	%100	-3,0%	3	8	2,7	1
Süsen Çiçeği	HIDER	1	8	-	%97,00	%100	-3,0%	3	5	1,7	2
Süsen Çiçeği	HIDER	1	9	-	%96,30	%100	-3,7%	3	9	3	1
Süsen Çiçeği	HIDER	2	0	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	2	1	-	%97,00	%93,30	%3,7	3	6	2	1
Süsen Çiçeği	HIDER	2	2	-	%97,80	%93,30	%4,5	3	9	3	2
Süsen Çiçeği	HIDER	2	3	-	%97,80	%93,30	%4,5	3	4	1,3	1
Süsen Çiçeği	HIDER	2	4	-	%97,00	%100	-3,0%	3	6	2	2
Süsen Çiçeği	HIDER	2	5	-	%97,80	%93,30	%4,5	3	6	2	1
Süsen Çiçeği	HIDER	2	6	-	%97,00	%93,30	%3,7	3	8	2,7	2
Süsen Çiçeği	HIDER	2	7	-	%97,00	%100	-3,0%	3	7	2,3	1
Süsen Çiçeği	HIDER	2	8	-	%97,00	%100	-3,0%	3	5	1,7	2
Süsen Çiçeği	HIDER	2	9	-	%96,30	%100	-3,7%	3	9	3	1
Süsen Çiçeği	HIDER	3	0	-	%97,80	%86,70	%11,1	3	5	1,7	2
Süsen Çiçeği	HIDER	3	1	-	%97,00	%93,30	%3,7	3	9	3	1
Süsen Çiçeği	HIDER	3	2	-	%97,80	%100	-2,2%	3	4	1,3	2
Süsen Çiçeği	HIDER	3	3	-	%97,80	%93,30	%4,5	3	6	2	1
Süsen Çiçeği	HIDER	3	4	-	%97,00	%100	-3,0%	3	8	2,7	2
Süsen Çiçeği	HIDER	3	5	-	%97,80	%93,30	%4,5	3	6	2	1
Süsen Çiçeği	HIDER	3	6	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	3	7	-	%97,00	%100	-3,0%	3	10	3,3	1
Süsen Çiçeği	HIDER	3	8	-	%97,00	%100	-3,0%	3	4	1,3	2
Süsen Çiçeği	HIDER	3	9	-	%97,00	%100	-3,0%	3	8	2,7	1
Süsen Çiçeği	HIDER	4	0	-	%97,80	%86,70	%11,1	3	5	1,7	2
Süsen Çiçeği	HIDER	4	1	-	%97,00	%93,30	%3,7	3	7	2,3	1
Süsen Çiçeği	HIDER	4	2	-	%97,80	%100	-2,2%	3	8	2,7	2
Süsen Çiçeği	HIDER	4	3	-	%97,80	%93,30	%4,5	3	4	1,3	1
Süsen Çiçeği	HIDER	4	4	-	%96,30	%100	-3,7%	3	8	2,7	2
Süsen Çiçeği	HIDER	4	5	-	%97,80	%93,30	%4,5	3	4	1,3	1
Süsen Çiçeği	HIDER	4	6	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	4	7	-	%97,00	%100	-3,0%	3	8	2,7	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Süsen Çiçeği	HIDER	4	8	-	%97,00	%100	-3,0%	3	5	1,7	2
Süsen Çiçeği	HIDER	4	9	-	%97,00	%100	-3,0%	3	6	2	1
Süsen Çiçeği	HIDER	5	0	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	5	1	-	%97,00	%93,30	%3,7	3	8	2,7	1
Süsen Çiçeği	HIDER	5	2	-	%97,80	%93,30	%4,5	3	7	2,3	2
Süsen Çiçeği	HIDER	5	3	-	%97,80	%93,30	%4,5	3	4	1,3	1
Süsen Çiçeği	HIDER	5	4	-	%97,00	%100	-3,0%	3	9	3	2
Süsen Çiçeği	HIDER	5	5	-	%97,80	%93,30	%4,5	3	5	1,7	1
Süsen Çiçeği	HIDER	5	6	-	%97,80	%93,30	%4,5	3	8	2,7	2
Süsen Çiçeği	HIDER	5	7	-	%96,30	%100	-3,7%	3	9	3	1
Süsen Çiçeği	HIDER	5	8	-	%97,00	%100	-3,0%	3	5	1,7	2
Süsen Çiçeği	HIDER	5	9	-	%97,00	%100	-3,0%	3	6	2	1
Süsen Çiçeği	LDWPSO	1	0	60.025	%97,78	%86,67	%11,1	3	3	1	5,2
Süsen Çiçeği	LDWPSO	1	1	60.017	%96,30	%86,67	%9,6	3	2	0,7	6,9
Süsen Çiçeği	LDWPSO	1	2	60.026	%97,78	%93,33	%4,4	3	3	1	7,7
Süsen Çiçeği	LDWPSO	1	3	60.022	%97,78	%100	-2,2%	3	3	1	6,8
Süsen Çiçeği	LDWPSO	1	4	60.026	%97,78	%100	-2,2%	3	3	1	8,4
Süsen Çiçeği	LDWPSO	1	5	60.022	%98,52	%93,33	%5,2	3	3	1	7,1
Süsen Çiçeği	LDWPSO	1	6	60.022	%98,52	%93,33	%5,2	3	3	1	7,2
Süsen Çiçeği	LDWPSO	1	7	60.022	%97,78	%86,67	%11,1	3	3	1	7,3
Süsen Çiçeği	LDWPSO	1	8	60.022	%97,78	%93,33	%4,4	3	3	1	7,8
Süsen Çiçeği	LDWPSO	1	9	60.022	%97,78	%86,67	%11,1	3	4	1,3	6
Süsen Çiçeği	LDWPSO	2	0	60.025	%97,78	%93,33	%4,4	3	3	1	6,6
Süsen Çiçeği	LDWPSO	2	1	60.017	%97,04	%86,67	%10,4	3	3	1	8,1
Süsen Çiçeği	LDWPSO	2	2	60.014	%96,30	%93,33	%3	3	2	0,7	8,1
Süsen Çiçeği	LDWPSO	2	3	60.012	%96,30	%93,33	%3	3	2	0,7	8
Süsen Çiçeği	LDWPSO	2	4	80.034	%98,52	%93,33	%5,2	5	7	1,4	8,7
Süsen Çiçeği	LDWPSO	2	5	60.016	%95,56	%100	-4,4%	3	2	0,7	7,4
Süsen Çiçeği	LDWPSO	2	6	80.034	%99,26	%86,67	%12,6	5	7	1,4	8,3
Süsen Çiçeği	LDWPSO	2	7	80.026	%97,78	%93,33	%4,4	5	8	1,6	8,1
Süsen Çiçeği	LDWPSO	2	8	60.014	%95,56	%100	-4,4%	3	2	0,7	7,7
Süsen Çiçeği	LDWPSO	2	9	80.036	%97,78	%93,33	%4,4	3	3	1	7,6
Süsen Çiçeği	LDWPSO	3	0	60.019	%96,30	%86,67	%9,6	4	3	0,8	7,2
Süsen Çiçeği	LDWPSO	3	1	60.019	%98,52	%93,33	%5,2	3	3	1	7,4
Süsen Çiçeği	LDWPSO	3	2	60.021	%95,56	%86,67	%8,9	4	4	1	7,9
Süsen Çiçeği	LDWPSO	3	3	60.015	%95,56	%93,33	%2,2	4	3	0,8	7,8
Süsen Çiçeği	LDWPSO	3	4	60.021	%95,56	%80,00	%15,6	4	3	0,8	8,3
Süsen Çiçeği	LDWPSO	3	5	60.019	%95,56	%86,67	%8,9	3	2	0,7	7,7
Süsen Çiçeği	LDWPSO	3	6	60.019	%96,30	%93,33	%3	4	3	0,8	7,8
Süsen Çiçeği	LDWPSO	3	7	60.021	%95,56	%86,67	%8,9	3	2	0,7	7,3
Süsen Çiçeği	LDWPSO	3	8	60.019	%95,56	%93,33	%2,2	3	2	0,7	7
Süsen Çiçeği	LDWPSO	3	9	60.024	%97,78	%86,67	%11,1	3	4	1,3	6,5
Süsen Çiçeği	LDWPSO	4	0	60.025	%97,78	%93,33	%4,4	3	3	1	7,4
Süsen Çiçeği	LDWPSO	4	1	60.019	%98,52	%93,33	%5,2	3	3	1	7,5
Süsen Çiçeği	LDWPSO	4	2	60.024	%97,78	%93,33	%4,4	3	3	1	8,6
Süsen Çiçeği	LDWPSO	4	3	60.022	%97,04	%93,33	%3,7	3	3	1	8,5
Süsen Çiçeği	LDWPSO	4	4	60.024	%97,78	%100	-2,2%	3	3	1	7,6
Süsen Çiçeği	LDWPSO	4	5	60.024	%98,52	%93,33	%5,2	3	3	1	8,2
Süsen Çiçeği	LDWPSO	4	6	60.020	%98,52	%93,33	%5,2	3	3	1	7,8
Süsen Çiçeği	LDWPSO	4	7	80.035	%97,78	%86,67	%11,1	3	3	1	7,3
Süsen Çiçeği	LDWPSO	4	8	60.020	%96,30	%100	-3,7%	3	3	1	6,8
Süsen Çiçeği	LDWPSO	4	9	60.017	%97,04	%93,33	%3,7	3	3	1	6,8
Süsen Çiçeği	LDWPSO	5	0	60.023	%97,78	%93,33	%4,4	3	3	1	6,2
Süsen Çiçeği	LDWPSO	5	1	60.020	%98,52	%86,67	%11,9	3	3	1	6,1
Süsen Çiçeği	LDWPSO	5	2	60.028	%97,78	%93,33	%4,4	3	3	1	6
Süsen Çiçeği	LDWPSO	5	3	60.019	%95,56	%93,33	%2,2	4	3	0,8	6,3
Süsen Çiçeği	LDWPSO	5	4	60.023	%97,78	%93,33	%4,4	3	3	1	6,3
Süsen Çiçeği	LDWPSO	5	5	60.027	%98,52	%93,33	%5,2	3	3	1	6,2
Süsen Çiçeği	LDWPSO	5	6	60.024	%98,52	%93,33	%5,2	3	3	1	6,1
Süsen Çiçeği	LDWPSO	5	7	60.023	%95,56	%86,67	%8,9	3	2	0,7	6,2
Süsen Çiçeği	LDWPSO	5	8	60.028	%97,78	%93,33	%4,4	3	3	1	6,3
Süsen Çiçeği	LDWPSO	5	9	60.020	%96,30	%86,67	%9,6	3	3	1	6,2
Süsen Çiçeği	PGIRLA	1	0	-	%98,52	%93,33	%5,2	20	34	1,7	1
Süsen Çiçeği	PGIRLA	1	1	-	%98,52	%80,00	%18,5	20	28	1,4	0,5
Süsen Çiçeği	PGIRLA	1	2	-	%98,52	%100	-1,5%	20	31	1,6	1
Süsen Çiçeği	PGIRLA	1	3	-	%98,52	%93,33	%5,2	20	28	1,4	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Süsen Çiçeği	PGIRLA	1	4	-	%98,52	%100	-1,5%	20	25	1,3	0,5
Süsen Çiçeği	PGIRLA	1	5	-	%98,52	%93,33	%5,2	20	33	1,7	1
Süsen Çiçeği	PGIRLA	1	6	-	%98,52	%100	-1,5%	20	28	1,4	1
Süsen Çiçeği	PGIRLA	1	7	-	%97,78	%100	-2,2%	20	32	1,6	0,5
Süsen Çiçeği	PGIRLA	1	8	-	%98,52	%100	-1,5%	20	25	1,3	1
Süsen Çiçeği	PGIRLA	1	9	-	%97,78	%100	-2,2%	20	27	1,4	1
Süsen Çiçeği	PGIRLA	2	0	-	%98,52	%93,33	%5,2	20	28	1,4	1
Süsen Çiçeği	PGIRLA	2	1	-	%98,52	%100	-1,5%	20	29	1,5	0,5
Süsen Çiçeği	PGIRLA	2	2	-	%98,52	%93,33	%5,2	20	32	1,6	1
Süsen Çiçeği	PGIRLA	2	3	-	%98,52	%93,33	%5,2	20	31	1,6	1
Süsen Çiçeği	PGIRLA	2	4	-	%98,52	%100	-1,5%	20	31	1,6	0,5
Süsen Çiçeği	PGIRLA	2	5	-	%99,26	%93,33	%5,9	20	35	1,8	1
Süsen Çiçeği	PGIRLA	2	6	-	%97,78	%93,33	%4,4	20	35	1,8	1
Süsen Çiçeği	PGIRLA	2	7	-	%97,78	%100	-2,2%	20	33	1,7	0,5
Süsen Çiçeği	PGIRLA	2	8	-	%97,04	%93,33	%3,7	20	28	1,4	1
Süsen Çiçeği	PGIRLA	2	9	-	%98,52	%100	-1,5%	20	29	1,5	1
Süsen Çiçeği	PGIRLA	3	0	-	%98,52	%80,00	%18,5	20	33	1,7	1
Süsen Çiçeği	PGIRLA	3	1	-	%98,52	%93,33	%5,2	20	35	1,8	0,5
Süsen Çiçeği	PGIRLA	3	2	-	%97,04	%93,33	%3,7	20	34	1,7	1
Süsen Çiçeği	PGIRLA	3	3	-	%98,52	%93,33	%5,2	20	29	1,5	1
Süsen Çiçeği	PGIRLA	3	4	-	%97,78	%100	-2,2%	20	39	2	0,5
Süsen Çiçeği	PGIRLA	3	5	-	%98,52	%100	-1,5%	20	39	2	1
Süsen Çiçeği	PGIRLA	3	6	-	%98,52	%100	-1,5%	20	31	1,6	1
Süsen Çiçeği	PGIRLA	3	7	-	%97,78	%100	-2,2%	20	34	1,7	0,5
Süsen Çiçeği	PGIRLA	3	8	-	%96,30	%100	-3,7%	20	24	1,2	1
Süsen Çiçeği	PGIRLA	3	9	-	%97,78	%100	-2,2%	20	30	1,5	1
Süsen Çiçeği	PGIRLA	4	0	-	%97,78	%93,33	%4,4	20	33	1,7	1
Süsen Çiçeği	PGIRLA	4	1	-	%98,52	%93,33	%5,2	20	29	1,5	0,5
Süsen Çiçeği	PGIRLA	4	2	-	%98,52	%100	-1,5%	20	30	1,5	1
Süsen Çiçeği	PGIRLA	4	3	-	%98,52	%93,33	%5,2	20	32	1,6	1
Süsen Çiçeği	PGIRLA	4	4	-	%97,04	%86,67	%10,4	20	33	1,7	0,5
Süsen Çiçeği	PGIRLA	4	5	-	%99,26	%93,33	%5,9	20	38	1,9	1
Süsen Çiçeği	PGIRLA	4	6	-	%99,26	%93,33	%5,9	20	24	1,2	1
Süsen Çiçeği	PGIRLA	4	7	-	%97,78	%100	-2,2%	20	32	1,6	0,5
Süsen Çiçeği	PGIRLA	4	8	-	%97,78	%93,33	%4,4	20	23	1,2	1
Süsen Çiçeği	PGIRLA	4	9	-	%97,78	%93,33	%4,4	20	31	1,6	1
Süsen Çiçeği	PGIRLA	5	0	-	%98,52	%80,00	%18,5	20	34	1,7	1
Süsen Çiçeği	PGIRLA	5	1	-	%98,52	%93,33	%5,2	20	37	1,9	0,5
Süsen Çiçeği	PGIRLA	5	2	-	%98,52	%93,33	%5,2	20	34	1,7	1
Süsen Çiçeği	PGIRLA	5	3	-	%98,52	%93,33	%5,2	20	34	1,7	1
Süsen Çiçeği	PGIRLA	5	4	-	%98,52	%100	-1,5%	20	32	1,6	0,5
Süsen Çiçeği	PGIRLA	5	5	-	%99,26	%86,67	%12,6	20	27	1,4	1
Süsen Çiçeği	PGIRLA	5	6	-	%98,52	%93,33	%5,2	20	26	1,3	1
Süsen Çiçeği	PGIRLA	5	7	-	%99,26	%100	-0,7%	20	35	1,8	0,5
Süsen Çiçeği	PGIRLA	5	8	-	%97,78	%100	-2,2%	20	35	1,8	1
Süsen Çiçeği	PGIRLA	5	9	-	%97,78	%100	-2,2%	20	29	1,5	1
Süsen Çiçeği	SIA	1	0	-	%100	%93,33	%6,7	15	45	3	1
Süsen Çiçeği	SIA	1	1	-	%100	%93,33	%6,7	17	50	2,9	1
Süsen Çiçeği	SIA	1	2	-	%100	%100	%0	14	38	2,7	1
Süsen Çiçeği	SIA	1	3	-	%100	%93,33	%6,7	11	41	3,7	1
Süsen Çiçeği	SIA	1	4	-	%100	%93,33	%6,7	15	55	3,7	1
Süsen Çiçeği	SIA	1	5	-	%100	%93,33	%6,7	11	55	5	1
Süsen Çiçeği	SIA	1	6	-	%100	%93,33	%6,7	15	31	2,1	1
Süsen Çiçeği	SIA	1	7	-	%100	%100	%0	14	47	3,4	1
Süsen Çiçeği	SIA	1	8	-	%100	%100	%0	13	39	3	1
Süsen Çiçeği	SIA	1	9	-	%100	%100	%0	13	45	3,5	1
Süsen Çiçeği	SIA	2	0	-	%100	%93,33	%6,7	15	48	3,2	1
Süsen Çiçeği	SIA	2	1	-	%100	%93,33	%6,7	10	42	4,2	1
Süsen Çiçeği	SIA	2	2	-	%100	%100	%0	16	50	3,1	1
Süsen Çiçeği	SIA	2	3	-	%100	%93,33	%6,7	14	50	3,6	1
Süsen Çiçeği	SIA	2	4	-	%100	%86,67	%13,3	13	51	3,9	1
Süsen Çiçeği	SIA	2	5	-	%100	%93,33	%6,7	13	36	2,8	1
Süsen Çiçeği	SIA	2	6	-	%100	%93,33	%6,7	13	41	3,2	1
Süsen Çiçeği	SIA	2	7	-	%100	%93,33	%6,7	20	38	1,9	1
Süsen Çiçeği	SIA	2	8	-	%100	%100	%0	14	48	3,4	1
Süsen Çiçeği	SIA	2	9	-	%100	%93,33	%6,7	14	44	3,1	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Süsen Çiçeği	SIA	3	0	-	%100	%93,33	%6,7	12	43	3,6	1
Süsen Çiçeği	SIA	3	1	-	%100	%86,67	%13,3	14	40	2,9	1
Süsen Çiçeği	SIA	3	2	-	%100	%100	%0	15	40	2,7	1
Süsen Çiçeği	SIA	3	3	-	%100	%93,33	%6,7	14	59	4,2	1
Süsen Çiçeği	SIA	3	4	-	%100	%100	%0	14	58	4,1	1
Süsen Çiçeği	SIA	3	5	-	%100	%93,33	%6,7	13	36	2,8	1
Süsen Çiçeği	SIA	3	6	-	%100	%93,33	%6,7	13	39	3	1
Süsen Çiçeği	SIA	3	7	-	%100	%100	%0	18	38	2,1	1
Süsen Çiçeği	SIA	3	8	-	%100	%100	%0	19	45	2,4	1
Süsen Çiçeği	SIA	3	9	-	%100	%93,33	%6,7	12	39	3,3	1
Süsen Çiçeği	SIA	4	0	-	%100	%93,33	%6,7	13	50	3,8	1
Süsen Çiçeği	SIA	4	1	-	%100	%86,67	%13,3	14	37	2,6	1
Süsen Çiçeği	SIA	4	2	-	%100	%100	%0	16	40	2,5	1
Süsen Çiçeği	SIA	4	3	-	%100	%93,33	%6,7	15	47	3,1	1
Süsen Çiçeği	SIA	4	4	-	%100	%100	%0	18	45	2,5	1
Süsen Çiçeği	SIA	4	5	-	%100	%86,67	%13,3	14	45	3,2	1
Süsen Çiçeği	SIA	4	6	-	%100	%100	%0	14	59	4,2	1
Süsen Çiçeği	SIA	4	7	-	%100	%100	%0	14	58	4,1	1
Süsen Çiçeği	SIA	4	8	-	%100	%93,33	%6,7	17	47	2,8	1
Süsen Çiçeği	SIA	4	9	-	%100	%100	%0	14	41	2,9	1
Süsen Çiçeği	SIA	5	0	-	%100	%93,33	%6,7	18	40	2,2	0,6
Süsen Çiçeği	SIA	5	1	-	%100	%86,67	%13,3	14	43	3,1	0,6
Süsen Çiçeği	SIA	5	2	-	%100	%100	%0	15	59	3,9	0,6
Süsen Çiçeği	SIA	5	3	-	%100	%93,33	%6,7	14	51	3,6	0,6
Süsen Çiçeği	SIA	5	4	-	%100	%100	%0	17	49	2,9	0,6
Süsen Çiçeği	SIA	5	5	-	%100	%93,33	%6,7	15	42	2,8	0,6
Süsen Çiçeği	SIA	5	6	-	%100	%93,33	%6,7	15	45	3	0,6
Süsen Çiçeği	SIA	5	7	-	%100	%100	%0	13	38	2,9	0,6
Süsen Çiçeği	SIA	5	8	-	%100	%100	%0	14	46	3,3	0,6
Süsen Çiçeği	SIA	5	9	-	%100	%100	%0	13	43	3,3	0,6
Taşıtlar	ABCMiner	1	0	144.672	%69,78	%31,76	%38	8	42	5,3	25,9
Taşıtlar	ABCMiner	1	1	143.125	%63,86	%43,53	%20,3	8	36	4,5	26,6
Taşıtlar	ABCMiner	1	2	142.738	%65,57	%55,29	%10,3	8	35	4,4	25
Taşıtlar	ABCMiner	1	3	143.122	%69,65	%55,29	%14,4	8	36	4,5	24,1
Taşıtlar	ABCMiner	1	4	142.797	%71,22	%60,00	%11,2	8	35	4,4	27,4
Taşıtlar	ABCMiner	1	5	143.512	%67,15	%49,41	%17,7	8	40	5	24,7
Taşıtlar	ABCMiner	1	6	150.235	%70,47	%47,62	%22,9	8	35	4,4	28,7
Taşıtlar	ABCMiner	1	7	145.091	%69,55	%58,33	%11,2	8	40	5	25,7
Taşıtlar	ABCMiner	1	8	143.285	%69,69	%40,48	%29,2	8	36	4,5	27,1
Taşıtlar	ABCMiner	1	9	142.346	%70,21	%29,76	%40,4	8	29	3,6	23,9
Taşıtlar	ABCMiner	2	0	143.124	%69,25	%40,00	%29,3	8	28	3,5	22,9
Taşıtlar	ABCMiner	2	1	142.791	%66,49	%50,59	%15,9	8	35	4,4	27,3
Taşıtlar	ABCMiner	2	2	142.596	%67,15	%32,94	%34,2	8	32	4	28,4
Taşıtlar	ABCMiner	2	3	143.561	%69,38	%60,00	%9,4	7	29	4,1	25
Taşıtlar	ABCMiner	2	4	142.229	%70,04	%40,00	%30	8	30	3,8	23,4
Taşıtlar	ABCMiner	2	5	142.593	%71,88	%50,59	%21,3	8	32	4	24,6
Taşıtlar	ABCMiner	2	6	142.798	%68,50	%54,76	%13,7	8	32	4	27
Taşıtlar	ABCMiner	2	7	142.315	%71,65	%60,71	%10,9	8	28	3,5	26,1
Taşıtlar	ABCMiner	2	8	142.648	%70,08	%45,24	%24,8	8	27	3,4	27,7
Taşıtlar	ABCMiner	2	9	142.774	%70,47	%39,29	%31,2	8	32	4	26,1
Taşıtlar	ABCMiner	3	0	142.374	%70,30	%49,41	%20,9	8	30	3,8	25,3
Taşıtlar	ABCMiner	3	1	142.934	%71,35	%44,71	%26,6	8	36	4,5	26,5
Taşıtlar	ABCMiner	3	2	142.671	%71,22	%42,35	%28,9	8	35	4,4	24,6
Taşıtlar	ABCMiner	3	3	143.783	%68,46	%61,18	%7,3	8	40	5	28,3
Taşıtlar	ABCMiner	3	4	143.294	%71,88	%57,65	%14,2	8	36	4,5	25,7
Taşıtlar	ABCMiner	3	5	142.961	%71,09	%55,29	%15,8	8	33	4,1	21,2
Taşıtlar	ABCMiner	3	6	143.018	%71,13	%53,57	%17,6	8	30	3,8	26,6
Taşıtlar	ABCMiner	3	7	143.794	%70,34	%51,19	%19,2	8	35	4,4	24,3
Taşıtlar	ABCMiner	3	8	147.396	%65,09	%45,24	%19,9	8	39	4,9	28,7
Taşıtlar	ABCMiner	3	9	143.223	%69,82	%44,05	%25,8	8	36	4,5	26
Taşıtlar	ABCMiner	4	0	143.516	%69,12	%38,82	%30,3	8	38	4,8	22,8
Taşıtlar	ABCMiner	4	1	142.573	%71,22	%44,71	%26,5	8	31	3,9	24,6
Taşıtlar	ABCMiner	4	2	143.795	%71,75	%47,06	%24,7	8	38	4,8	25
Taşıtlar	ABCMiner	4	3	145.773	%71,75	%63,53	%8,2	8	41	5,1	27,6
Taşıtlar	ABCMiner	4	4	163.319	%72,93	%43,53	%29,4	9	36	4	26,8
Taşıtlar	ABCMiner	4	5	143.060	%66,36	%43,53	%22,8	8	40	5	25,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Taşıtlar	ABCMiner	4	6	165.385	%66,40	%54,76	%11,6	9	42	4,7	25,6
Taşıtlar	ABCMiner	4	7	142.536	%69,82	%58,33	%11,5	8	33	4,1	23,9
Taşıtlar	ABCMiner	4	8	143.250	%70,34	%42,86	%27,5	8	37	4,6	25,9
Taşıtlar	ABCMiner	4	9	143.099	%73,10	%52,38	%20,7	8	35	4,4	24,5
Taşıtlar	ABCMiner	5	0	142.535	%69,38	%47,06	%22,3	8	34	4,3	22,7
Taşıtlar	ABCMiner	5	1	144.299	%72,27	%38,82	%33,4	8	39	4,9	24,4
Taşıtlar	ABCMiner	5	2	142.445	%70,83	%60,00	%10,8	8	30	3,8	23,5
Taşıtlar	ABCMiner	5	3	143.249	%70,04	%51,76	%18,3	8	36	4,5	24,2
Taşıtlar	ABCMiner	5	4	143.542	%65,83	%40,00	%25,8	8	38	4,8	25,6
Taşıtlar	ABCMiner	5	5	142.988	%65,18	%47,06	%18,1	8	36	4,5	23,8
Taşıtlar	ABCMiner	5	6	142.249	%69,42	%55,95	%13,5	8	26	3,3	21,5
Taşıtlar	ABCMiner	5	7	143.639	%68,90	%55,95	%12,9	8	40	5	26,3
Taşıtlar	ABCMiner	5	8	142.773	%68,77	%41,67	%27,1	8	31	3,9	25,6
Taşıtlar	ABCMiner	5	9	143.160	%67,06	%36,90	%30,2	8	41	5,1	24,5
Taşıtlar	C4.5	-	1	-	%73,19	%75,29	-2,1%	18	33	1,8	1,2
Taşıtlar	C4.5	-	2	-	%72,93	%63,53	%9,4	18	27	1,5	1,2
Taşıtlar	C4.5	-	3	-	%70,30	%69,41	%0,9	19	45	2,4	1,2
Taşıtlar	C4.5	-	4	-	%72,27	%65,88	%6,4	17	33	1,9	1,2
Taşıtlar	C4.5	-	5	-	%70,43	%65,88	%4,6	16	28	1,8	1,2
Taşıtlar	C4.5	-	6	-	%71,22	%58,82	%12,4	23	44	1,9	1,2
Taşıtlar	C4.5	-	7	-	%69,69	%63,10	%6,6	17	29	1,7	1,2
Taşıtlar	C4.5	-	8	-	%67,85	%61,90	%5,9	17	31	1,8	1,2
Taşıtlar	C4.5	-	9	-	%73,36	%72,62	%0,7	18	37	2,1	1,2
Taşıtlar	C4.5	-	10	-	%71,39	%69,05	%2,3	20	38	1,9	1,2
Taşıtlar	CoABCMiner	1	0	110.552	%68,99	%65,88	%3,1	29	173	6	6,7
Taşıtlar	CoABCMiner	1	1	110.544	%69,38	%68,24	%1,1	25	163	6,5	6,1
Taşıtlar	CoABCMiner	1	2	110.578	%67,41	%63,53	%3,9	24	175	7,3	6,1
Taşıtlar	CoABCMiner	1	3	110.519	%70,17	%63,53	%6,6	25	183	7,3	6,4
Taşıtlar	CoABCMiner	1	4	110.543	%67,67	%65,88	%1,8	21	125	6	6,5
Taşıtlar	CoABCMiner	1	5	110.559	%69,91	%62,35	%7,6	24	169	7	6,3
Taşıtlar	CoABCMiner	1	6	110.556	%70,08	%63,10	%7	26	151	5,8	6
Taşıtlar	CoABCMiner	1	7	110.549	%69,42	%66,67	%2,8	25	159	6,4	6
Taşıtlar	CoABCMiner	1	8	110.531	%68,24	%66,67	%1,6	25	164	6,6	5,7
Taşıtlar	CoABCMiner	1	9	110.589	%67,72	%65,48	%2,2	24	171	7,1	5,6
Taşıtlar	CoABCMiner	2	0	110.547	%70,04	%69,41	%0,6	29	199	6,9	6,2
Taşıtlar	CoABCMiner	2	1	110.548	%70,17	%69,41	%0,8	23	154	6,7	6,2
Taşıtlar	CoABCMiner	2	2	110.525	%69,38	%75,29	-5,9%	27	200	7,4	6,2
Taşıtlar	CoABCMiner	2	3	110.583	%67,81	%70,59	-2,8%	25	144	5,8	6,1
Taşıtlar	CoABCMiner	2	4	110.573	%68,46	%69,41	-0,9%	27	177	6,6	6,3
Taşıtlar	CoABCMiner	2	5	110.525	%67,41	%56,47	%10,9	29	199	6,9	6
Taşıtlar	CoABCMiner	2	6	110.569	%70,73	%69,05	%1,7	28	188	6,7	5,8
Taşıtlar	CoABCMiner	2	7	110.571	%67,45	%65,48	%2	29	187	6,4	5,8
Taşıtlar	CoABCMiner	2	8	110.580	%69,29	%69,05	%0,2	25	137	5,5	5,8
Taşıtlar	CoABCMiner	2	9	110.589	%69,82	%69,05	%0,8	24	124	5,2	5,6
Taşıtlar	CoABCMiner	3	0	110.520	%67,81	%67,06	%0,7	26	205	7,9	6,2
Taşıtlar	CoABCMiner	3	1	110.567	%70,30	%69,41	%0,9	23	142	6,2	5,7
Taşıtlar	CoABCMiner	3	2	110.550	%71,09	%72,94	-1,9%	29	195	6,7	5,8
Taşıtlar	CoABCMiner	3	3	110.557	%68,33	%63,53	%4,8	27	176	6,5	5,8
Taşıtlar	CoABCMiner	3	4	110.577	%68,99	%70,59	-1,6%	25	164	6,6	5,7
Taşıtlar	CoABCMiner	3	5	110.584	%69,25	%61,18	%8,1	25	114	4,6	5,8
Taşıtlar	CoABCMiner	3	6	110.546	%69,69	%66,67	%3	27	163	6	5,8
Taşıtlar	CoABCMiner	3	7	110.591	%71,00	%65,48	%5,5	22	145	6,6	5,9
Taşıtlar	CoABCMiner	3	8	110.530	%69,03	%70,24	-1,2%	26	168	6,5	5,9
Taşıtlar	CoABCMiner	3	9	110.503	%70,87	%72,62	-1,8%	25	181	7,2	6,2
Taşıtlar	CoABCMiner	4	0	110.537	%70,83	%67,06	%3,8	21	132	6,3	5,8
Taşıtlar	CoABCMiner	4	1	110.593	%66,75	%56,47	%10,3	27	185	6,9	5,7
Taşıtlar	CoABCMiner	4	2	110.586	%70,30	%69,41	%0,9	29	175	6	5,6
Taşıtlar	CoABCMiner	4	3	110.575	%69,91	%70,59	-0,7%	28	185	6,6	5,7
Taşıtlar	CoABCMiner	4	4	110.500	%69,91	%63,53	%6,4	24	146	6,1	5,9
Taşıtlar	CoABCMiner	4	5	110.549	%69,51	%67,06	%2,5	27	173	6,4	5,7
Taşıtlar	CoABCMiner	4	6	110.582	%69,42	%67,86	%1,6	25	178	7,1	5,8
Taşıtlar	CoABCMiner	4	7	110.552	%70,34	%69,05	%1,3	22	147	6,7	5,7
Taşıtlar	CoABCMiner	4	8	110.561	%70,21	%71,43	-1,2%	23	141	6,1	5,9
Taşıtlar	CoABCMiner	4	9	110.572	%69,55	%61,90	%7,6	25	177	7,1	5,8
Taşıtlar	CoABCMiner	5	0	110.554	%69,51	%65,88	%3,6	24	157	6,5	5,9
Taşıtlar	CoABCMiner	5	1	110.572	%69,91	%67,06	%2,8	26	170	6,5	5,7

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Taşıtlar	CoABCMiner	5	2	110.540	%70,57	%69,41	%1,2	25	166	6,6	6
Taşıtlar	CoABCMiner	5	3	110.554	%69,51	%65,88	%3,6	28	205	7,3	5,8
Taşıtlar	CoABCMiner	5	4	110.555	%67,81	%67,06	%0,7	25	156	6,2	5,7
Taşıtlar	CoABCMiner	5	5	110.542	%69,25	%57,65	%11,6	24	140	5,8	5,8
Taşıtlar	CoABCMiner	5	6	110.565	%68,24	%64,29	%4	27	175	6,5	5,7
Taşıtlar	CoABCMiner	5	7	110.538	%69,42	%70,24	-0,8%	29	153	5,3	5,9
Taşıtlar	CoABCMiner	5	8	110.583	%69,69	%72,62	-2,9%	31	169	5,5	5,6
Taşıtlar	CoABCMiner	5	9	110.527	%70,87	%67,86	%3	26	148	5,7	6
Taşıtlar	CORE	1	0	1.962.115	%54,40	%54,12	%0,3	13	53	4,1	164,6
Taşıtlar	CORE	1	1	1.962.323	%41,92	%37,65	%4,3	14	54	3,9	173,3
Taşıtlar	CORE	1	2	1.963.740	%54,80	%51,76	%3	8	26	3,3	175,2
Taşıtlar	CORE	1	3	1.965.030	%56,11	%54,12	%2	12	51	4,3	175,1
Taşıtlar	CORE	1	4	1.965.177	%54,14	%52,94	%1,2	11	47	4,3	189,7
Taşıtlar	CORE	1	5	1.964.103	%54,53	%48,24	%6,3	6	25	4,2	166,9
Taşıtlar	CORE	1	6	1.964.120	%49,48	%54,76	-5,3%	12	50	4,2	159,4
Taşıtlar	CORE	1	7	1.962.550	%58,53	%58,33	%0,2	12	63	5,3	171,7
Taşıtlar	CORE	1	8	1.965.293	%61,68	%66,67	-5,0%	9	34	3,8	175,5
Taşıtlar	CORE	1	9	1.963.222	%59,71	%54,76	%4,9	10	58	5,8	174,7
Taşıtlar	CORE	2	0	-	%59,66	%58,82	%0,8	8	37	4,6	165,5
Taşıtlar	CORE	2	1	-	%66,49	%58,82	%7,7	6	26	4,3	171,4
Taşıtlar	CORE	2	2	-	%54,80	%55,29	-0,5%	10	46	4,6	170,9
Taşıtlar	CORE	2	3	-	%47,70	%43,53	%4,2	10	45	4,5	167,8
Taşıtlar	CORE	2	4	-	%64,91	%61,18	%3,7	10	36	3,6	168,8
Taşıtlar	CORE	2	5	-	%60,32	%55,29	%5	13	47	3,6	161,6
Taşıtlar	CORE	2	6	-	%51,71	%45,24	%6,5	15	76	5,1	178,4
Taşıtlar	CORE	2	7	-	%61,68	%58,33	%3,3	7	31	4,4	165,1
Taşıtlar	CORE	2	8	-	%63,25	%67,86	-4,6%	12	39	3,3	166,3
Taşıtlar	CORE	2	9	-	%60,89	%57,14	%3,7	9	36	4	176,1
Taşıtlar	CORE	3	0	-	%57,03	%48,24	%8,8	11	43	3,9	156,3
Taşıtlar	CORE	3	1	-	%65,83	%65,88	%0	11	46	4,2	160
Taşıtlar	CORE	3	2	-	%64,65	%68,24	-3,6%	12	53	4,4	157,4
Taşıtlar	CORE	3	3	-	%59,66	%57,65	%2	5	18	3,6	161,7
Taşıtlar	CORE	3	4	-	%59,92	%60,00	-0,1%	14	67	4,8	165,2
Taşıtlar	CORE	3	5	-	%59,79	%47,06	%12,7	12	48	4	161,3
Taşıtlar	CORE	3	6	-	%65,49	%59,52	%6	7	27	3,9	158,2
Taşıtlar	CORE	3	7	-	%63,91	%65,48	-1,6%	12	44	3,7	162,8
Taşıtlar	CORE	3	8	-	%67,19	%71,43	-4,2%	12	47	3,9	162,4
Taşıtlar	CORE	3	9	-	%59,32	%59,52	-0,2%	12	56	4,7	171,4
Taşıtlar	CORE	4	0	-	%63,47	%55,29	%8,2	9	33	3,7	172,9
Taşıtlar	CORE	4	1	-	%61,50	%55,29	%6,2	5	22	4,4	184,2
Taşıtlar	CORE	4	2	-	%58,61	%56,47	%2,1	9	44	4,9	186,4
Taşıtlar	CORE	4	3	-	%64,78	%70,59	-5,8%	14	65	4,6	179,4
Taşıtlar	CORE	4	4	-	%62,16	%58,82	%3,3	12	60	5	177,5
Taşıtlar	CORE	4	5	-	%57,82	%45,88	%11,9	9	41	4,6	174,4
Taşıtlar	CORE	4	6	-	%62,07	%55,95	%6,1	10	37	3,7	174,6
Taşıtlar	CORE	4	7	-	%60,89	%58,33	%2,6	7	26	3,7	168,6
Taşıtlar	CORE	4	8	-	%60,37	%64,29	-3,9%	11	35	3,2	173
Taşıtlar	CORE	4	9	-	%63,25	%59,52	%3,7	12	58	4,8	160,9
Taşıtlar	CORE	5	0	-	%49,41	%48,24	%1,2	10	38	3,8	149,9
Taşıtlar	CORE	5	1	-	%62,55	%57,65	%4,9	10	38	3,8	187,6
Taşıtlar	CORE	5	2	-	%63,07	%67,06	-4,0%	7	32	4,6	183,3
Taşıtlar	CORE	5	3	-	%55,85	%55,29	%0,6	7	32	4,6	173,6
Taşıtlar	CORE	5	4	-	%63,34	%67,06	-3,7%	12	62	5,2	182,2
Taşıtlar	CORE	5	5	-	%52,96	%43,53	%9,4	14	51	3,6	185,6
Taşıtlar	CORE	5	6	-	%58,27	%63,10	-4,8%	10	46	4,6	186,1
Taşıtlar	CORE	5	7	-	%46,72	%46,43	%0,3	7	34	4,9	179,9
Taşıtlar	CORE	5	8	-	%63,52	%67,86	-4,3%	14	67	4,8	184,6
Taşıtlar	CORE	5	9	-	%61,42	%57,14	%4,3	11	55	5	177,9
Taşıtlar	HIDER	1	0	-	%80,30	%58,80	%21,5	43	748	17,4	57
Taşıtlar	HIDER	1	1	-	%81,30	%50,60	%30,7	47	821	17,5	59
Taşıtlar	HIDER	1	2	-	%80,40	%61,20	%19,2	43	740	17,2	59
Taşıtlar	HIDER	1	3	-	%82,50	%58,80	%23,7	50	883	17,7	69
Taşıtlar	HIDER	1	4	-	%81,10	%60,00	%21,1	44	769	17,5	60
Taşıtlar	HIDER	1	5	-	%82,10	%56,50	%25,6	45	787	17,5	61
Taşıtlar	HIDER	1	6	-	%83,10	%60,70	%22,4	46	796	17,3	66
Taşıtlar	HIDER	1	7	-	%81,50	%61,90	%19,6	44	747	17	64

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Taşıtlar	HIDER	1	8	-	%83,10	%59,50	%23,6	44	770	17,5	58
Taşıtlar	HIDER	1	9	-	%83,50	%45,20	%38,3	46	807	17,5	62
Taşıtlar	HIDER	2	0	-	%81,50	%65,90	%15,6	51	884	17,3	57
Taşıtlar	HIDER	2	1	-	%83,80	%57,60	%26,2	52	908	17,5	59
Taşıtlar	HIDER	2	2	-	%81,90	%60,00	%21,9	44	768	17,5	59
Taşıtlar	HIDER	2	3	-	%85,30	%54,10	%31,2	49	858	17,5	69
Taşıtlar	HIDER	2	4	-	%84,60	%48,20	%36,4	46	797	17,3	60
Taşıtlar	HIDER	2	5	-	%84,20	%58,80	%25,4	49	857	17,5	61
Taşıtlar	HIDER	2	6	-	%82,80	%65,50	%17,3	44	755	17,2	66
Taşıtlar	HIDER	2	7	-	%82,40	%58,30	%24,1	47	820	17,4	64
Taşıtlar	HIDER	2	8	-	%84,30	%59,50	%24,8	41	711	17,3	58
Taşıtlar	HIDER	2	9	-	%82,30	%56,00	%26,3	45	783	17,4	62
Taşıtlar	HIDER	3	0	-	%84,50	%63,50	%21	50	876	17,5	57
Taşıtlar	HIDER	3	1	-	%80,30	%62,40	%17,9	45	786	17,5	59
Taşıtlar	HIDER	3	2	-	%84,60	%61,20	%23,4	53	915	17,3	59
Taşıtlar	HIDER	3	3	-	%83,20	%56,50	%26,7	46	815	17,7	69
Taşıtlar	HIDER	3	4	-	%82,50	%50,60	%31,9	44	760	17,3	60
Taşıtlar	HIDER	3	5	-	%83,80	%50,60	%33,2	48	841	17,5	61
Taşıtlar	HIDER	3	6	-	%83,30	%61,90	%21,4	44	757	17,2	66
Taşıtlar	HIDER	3	7	-	%82,40	%59,50	%22,9	43	728	16,9	64
Taşıtlar	HIDER	3	8	-	%84,30	%61,90	%22,4	51	883	17,3	58
Taşıtlar	HIDER	3	9	-	%83,10	%59,50	%23,6	47	821	17,5	62
Taşıtlar	HIDER	4	0	-	%84,20	%63,50	%20,7	59	1024	17,4	57
Taşıtlar	HIDER	4	1	-	%83,20	%58,80	%24,4	41	705	17,2	59
Taşıtlar	HIDER	4	2	-	%82,40	%61,20	%21,2	46	798	17,3	59
Taşıtlar	HIDER	4	3	-	%83,00	%65,90	%17,1	43	762	17,7	69
Taşıtlar	HIDER	4	4	-	%83,20	%60,00	%23,2	48	827	17,2	60
Taşıtlar	HIDER	4	5	-	%82,50	%60,00	%22,5	41	712	17,4	61
Taşıtlar	HIDER	4	6	-	%83,70	%64,30	%19,4	41	698	17	66
Taşıtlar	HIDER	4	7	-	%82,20	%60,70	%21,5	48	819	17,1	64
Taşıtlar	HIDER	4	8	-	%84,90	%65,50	%19,4	43	741	17,2	58
Taşıtlar	HIDER	4	9	-	%84,60	%59,50	%25,1	50	867	17,3	62
Taşıtlar	HIDER	5	0	-	%81,90	%68,20	%13,7	47	813	17,3	57
Taşıtlar	HIDER	5	1	-	%80,80	%58,80	%22	42	728	17,3	59
Taşıtlar	HIDER	5	2	-	%82,80	%62,40	%20,4	48	826	17,2	59
Taşıtlar	HIDER	5	3	-	%83,80	%63,50	%20,3	45	786	17,5	69
Taşıtlar	HIDER	5	4	-	%85,80	%62,40	%23,4	52	908	17,5	60
Taşıtlar	HIDER	5	5	-	%82,90	%65,90	%17	44	776	17,6	61
Taşıtlar	HIDER	5	6	-	%82,30	%56,00	%26,3	44	760	17,3	66
Taşıtlar	HIDER	5	7	-	%84,40	%65,50	%18,9	47	812	17,3	64
Taşıtlar	HIDER	5	8	-	%82,70	%63,10	%19,6	42	730	17,4	58
Taşıtlar	HIDER	5	9	-	%84,00	%60,70	%23,3	47	815	17,3	62
Taşıtlar	LDWPSO	1	0	141.037	%68,86	%38,82	%30	8	32	4	72,4
Taşıtlar	LDWPSO	1	1	140.778	%69,65	%55,29	%14,4	8	22	2,8	76,7
Taşıtlar	LDWPSO	1	2	140.927	%64,13	%56,47	%7,7	8	31	3,9	77,1
Taşıtlar	LDWPSO	1	3	160.977	%66,36	%67,06	-0,7%	9	35	3,9	81,2
Taşıtlar	LDWPSO	1	4	140.589	%68,33	%51,76	%16,6	8	28	3,5	74,7
Taşıtlar	LDWPSO	1	5	140.985	%69,78	%57,65	%12,1	8	30	3,8	76,5
Taşıtlar	LDWPSO	1	6	140.874	%60,89	%50,00	%10,9	8	29	3,6	84,8
Taşıtlar	LDWPSO	1	7	141.356	%63,39	%52,38	%11	8	31	3,9	86,6
Taşıtlar	LDWPSO	1	8	140.686	%67,19	%55,95	%11,2	8	25	3,1	80,3
Taşıtlar	LDWPSO	1	9	161.208	%68,90	%35,71	%33,2	9	34	3,8	80,9
Taşıtlar	LDWPSO	2	0	140.635	%63,07	%44,71	%18,4	8	25	3,1	77,6
Taşıtlar	LDWPSO	2	1	161.109	%56,77	%36,47	%20,3	9	35	3,9	88,8
Taşıtlar	LDWPSO	2	2	160.940	%67,94	%45,88	%22,1	9	32	3,6	76
Taşıtlar	LDWPSO	2	3	160.736	%67,67	%64,71	%3	9	31	3,4	73,5
Taşıtlar	LDWPSO	2	4	161.300	%69,51	%56,47	%13	9	38	4,2	77,6
Taşıtlar	LDWPSO	2	5	141.307	%62,02	%40,00	%22	8	33	4,1	87,4
Taşıtlar	LDWPSO	2	6	140.721	%64,83	%55,95	%8,9	8	26	3,3	70,1
Taşıtlar	LDWPSO	2	7	160.981	%70,34	%54,76	%15,6	9	35	3,9	75,1
Taşıtlar	LDWPSO	2	8	140.441	%64,30	%57,14	%7,2	8	21	2,6	77,4
Taşıtlar	LDWPSO	2	9	141.049	%61,02	%46,43	%14,6	8	32	4	85,1
Taşıtlar	LDWPSO	3	0	140.500	%70,57	%54,12	%16,4	8	23	2,9	77
Taşıtlar	LDWPSO	3	1	140.629	%69,12	%47,06	%22,1	8	25	3,1	84,4
Taşıtlar	LDWPSO	3	2	140.743	%70,04	%47,06	%23	8	24	3	75,9
Taşıtlar	LDWPSO	3	3	140.956	%62,16	%54,12	%8	8	35	4,4	87,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Taşıtlar	LDWPSO	3	4	140.578	%65,57	%56,47	%9,1	8	26	3,3	75,3
Taşıtlar	LDWPSO	3	5	161.055	%61,50	%43,53	%18	9	31	3,4	91,7
Taşıtlar	LDWPSO	3	6	140.743	%56,30	%44,05	%12,3	8	28	3,5	81,4
Taşıtlar	LDWPSO	3	7	141.170	%58,92	%35,71	%23,2	8	33	4,1	82,3
Taşıtlar	LDWPSO	3	8	140.584	%68,77	%58,33	%10,4	8	25	3,1	74,8
Taşıtlar	LDWPSO	3	9	160.659	%64,96	%50,00	%15	9	25	2,8	73,8
Taşıtlar	LDWPSO	4	0	160.839	%68,07	%36,47	%31,6	9	32	3,6	86,2
Taşıtlar	LDWPSO	4	1	140.983	%65,70	%50,59	%15,1	8	30	3,8	88,4
Taşıtlar	LDWPSO	4	2	140.708	%67,54	%55,29	%12,2	8	25	3,1	85,9
Taşıtlar	LDWPSO	4	3	140.852	%59,53	%54,12	%5,4	8	31	3,9	82,9
Taşıtlar	LDWPSO	4	4	161.246	%68,46	%58,82	%9,6	9	39	4,3	90,1
Taşıtlar	LDWPSO	4	5	160.832	%68,20	%48,24	%20	9	31	3,4	82,3
Taşıtlar	LDWPSO	4	6	140.650	%68,64	%51,19	%17,4	8	29	3,6	78,2
Taşıtlar	LDWPSO	4	7	160.967	%71,39	%47,62	%23,8	9	34	3,8	83,1
Taşıtlar	LDWPSO	4	8	160.898	%66,67	%57,14	%9,5	8	27	3,4	88,2
Taşıtlar	LDWPSO	4	9	160.966	%67,72	%45,24	%22,5	9	29	3,2	72
Taşıtlar	LDWPSO	5	0	140.785	%59,26	%42,35	%16,9	8	24	3	68,3
Taşıtlar	LDWPSO	5	1	141.368	%62,29	%52,94	%9,3	8	34	4,3	70,4
Taşıtlar	LDWPSO	5	2	161.008	%63,21	%40,00	%23,2	9	32	3,6	81,4
Taşıtlar	LDWPSO	5	3	161.078	%61,63	%55,29	%6,3	9	33	3,7	78,9
Taşıtlar	LDWPSO	5	4	140.831	%62,02	%48,24	%13,8	8	28	3,5	66,3
Taşıtlar	LDWPSO	5	5	140.823	%62,94	%50,59	%12,4	8	30	3,8	64,7
Taşıtlar	LDWPSO	5	6	140.678	%65,22	%54,76	%10,5	8	23	2,9	63,9
Taşıtlar	LDWPSO	5	7	140.933	%70,21	%53,57	%16,6	8	30	3,8	61,2
Taşıtlar	LDWPSO	5	8	160.908	%67,59	%52,38	%15,2	9	31	3,4	70,8
Taşıtlar	LDWPSO	5	9	140.687	%61,42	%45,24	%16,2	8	25	3,1	70,9
Taşıtlar	PGIRLA	1	0	-	%52,04	%48,24	%3,8	20	153	7,7	3
Taşıtlar	PGIRLA	1	1	-	%47,96	%43,53	%4,4	20	151	7,6	3
Taşıtlar	PGIRLA	1	2	-	%52,17	%49,41	%2,8	20	147	7,4	3
Taşıtlar	PGIRLA	1	3	-	%61,76	%51,76	%10	20	136	6,8	4
Taşıtlar	PGIRLA	1	4	-	%56,77	%51,76	%5	20	134	6,7	3
Taşıtlar	PGIRLA	1	5	-	%60,05	%51,76	%8,3	20	143	7,2	3
Taşıtlar	PGIRLA	1	6	-	%49,34	%45,24	%4,1	20	152	7,6	3
Taşıtlar	PGIRLA	1	7	-	%55,25	%53,57	%1,7	20	138	6,9	3
Taşıtlar	PGIRLA	1	8	-	%53,94	%48,81	%5,1	20	146	7,3	3
Taşıtlar	PGIRLA	1	9	-	%54,20	%53,57	%0,6	20	141	7,1	4
Taşıtlar	PGIRLA	2	0	-	%60,97	%54,12	%6,9	20	148	7,4	3
Taşıtlar	PGIRLA	2	1	-	%62,81	%58,82	%4	20	151	7,6	3
Taşıtlar	PGIRLA	2	2	-	%56,77	%50,59	%6,2	20	134	6,7	3
Taşıtlar	PGIRLA	2	3	-	%57,69	%45,88	%11,8	20	139	7	4
Taşıtlar	PGIRLA	2	4	-	%54,27	%61,18	-6,9%	20	144	7,2	3
Taşıtlar	PGIRLA	2	5	-	%58,87	%51,76	%7,1	20	146	7,3	3
Taşıtlar	PGIRLA	2	6	-	%59,58	%58,33	%1,2	20	139	7	3
Taşıtlar	PGIRLA	2	7	-	%59,71	%57,14	%2,6	20	148	7,4	3
Taşıtlar	PGIRLA	2	8	-	%58,40	%61,90	-3,5%	20	145	7,3	3
Taşıtlar	PGIRLA	2	9	-	%46,33	%44,05	%2,3	20	143	7,2	4
Taşıtlar	PGIRLA	3	0	-	%52,17	%45,88	%6,3	20	165	8,3	3
Taşıtlar	PGIRLA	3	1	-	%59,00	%56,47	%2,5	20	149	7,5	3
Taşıtlar	PGIRLA	3	2	-	%59,13	%56,47	%2,7	20	146	7,3	3
Taşıtlar	PGIRLA	3	3	-	%53,22	%56,47	-3,3%	20	153	7,7	4
Taşıtlar	PGIRLA	3	4	-	%51,25	%56,47	-5,2%	20	144	7,2	3
Taşıtlar	PGIRLA	3	5	-	%58,08	%51,76	%6,3	20	139	7	3
Taşıtlar	PGIRLA	3	6	-	%52,23	%45,24	%7	20	143	7,2	3
Taşıtlar	PGIRLA	3	7	-	%56,56	%52,38	%4,2	20	147	7,4	3
Taşıtlar	PGIRLA	3	8	-	%64,83	%64,29	%0,5	20	130	6,5	3
Taşıtlar	PGIRLA	3	9	-	%56,17	%48,81	%7,4	20	146	7,3	4
Taşıtlar	PGIRLA	4	0	-	%61,63	%57,65	%4	20	143	7,2	3
Taşıtlar	PGIRLA	4	1	-	%54,27	%48,24	%6	20	145	7,3	3
Taşıtlar	PGIRLA	4	2	-	%51,64	%62,35	-10,7%	20	152	7,6	3
Taşıtlar	PGIRLA	4	3	-	%59,66	%60,00	-0,3%	20	153	7,7	4
Taşıtlar	PGIRLA	4	4	-	%54,27	%56,47	-2,2%	20	151	7,6	3
Taşıtlar	PGIRLA	4	5	-	%55,19	%47,06	%8,1	20	168	8,4	3
Taşıtlar	PGIRLA	4	6	-	%56,04	%50,00	%6	20	137	6,9	3
Taşıtlar	PGIRLA	4	7	-	%61,29	%54,76	%6,5	20	137	6,9	3
Taşıtlar	PGIRLA	4	8	-	%54,86	%53,57	%1,3	20	145	7,3	3
Taşıtlar	PGIRLA	4	9	-	%54,72	%50,00	%4,7	20	149	7,5	4

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Taşıtlar	PGIRLA	5	0	-	%54,01	%49,41	%4,6	20	145	7,3	3
Taşıtlar	PGIRLA	5	1	-	%57,56	%56,47	%1,1	20	173	8,7	3
Taşıtlar	PGIRLA	5	2	-	%56,64	%47,06	%9,6	20	132	6,6	3
Taşıtlar	PGIRLA	5	3	-	%54,01	%43,53	%10,5	20	157	7,9	4
Taşıtlar	PGIRLA	5	4	-	%61,63	%57,65	%4	20	151	7,6	3
Taşıtlar	PGIRLA	5	5	-	%57,42	%45,88	%11,5	20	150	7,5	3
Taşıtlar	PGIRLA	5	6	-	%53,67	%46,43	%7,2	20	153	7,7	3
Taşıtlar	PGIRLA	5	7	-	%54,46	%53,57	%0,9	20	161	8,1	3
Taşıtlar	PGIRLA	5	8	-	%58,92	%59,52	-0,6%	20	133	6,7	3
Taşıtlar	PGIRLA	5	9	-	%56,43	%52,38	%4	20	158	7,9	4
Taşıtlar	SIA	1	0	-	%100	%64,71	%35,3	690	12228	17,7	93
Taşıtlar	SIA	1	1	-	%100	%57,65	%42,4	655	11815	18	94
Taşıtlar	SIA	1	2	-	%100	%65,88	%34,1	696	12248	17,6	103
Taşıtlar	SIA	1	3	-	%100	%62,35	%37,6	689	11964	17,4	104
Taşıtlar	SIA	1	4	-	%100	%57,65	%42,4	686	11966	17,4	108
Taşıtlar	SIA	1	5	-	%100	%56,47	%43,5	701	11606	16,6	104
Taşıtlar	SIA	1	6	-	%100	%59,52	%40,5	714	11821	16,6	121
Taşıtlar	SIA	1	7	-	%100	%61,90	%38,1	700	12242	17,5	96
Taşıtlar	SIA	1	8	-	%100	%70,24	%29,8	710	12362	17,4	108
Taşıtlar	SIA	1	9	-	%100	%73,81	%26,2	709	12114	17,1	110
Taşıtlar	SIA	2	0	-	%100	%62,35	%37,6	667	12345	18,5	116
Taşıtlar	SIA	2	1	-	%100	%55,29	%44,7	666	12172	18,3	111
Taşıtlar	SIA	2	2	-	%100	%61,18	%38,8	687	12276	17,9	112
Taşıtlar	SIA	2	3	-	%100	%62,35	%37,6	692	11949	17,3	116
Taşıtlar	SIA	2	4	-	%100	%65,88	%34,1	704	12261	17,4	99
Taşıtlar	SIA	2	5	-	%100	%62,35	%37,6	676	12192	18	98
Taşıtlar	SIA	2	6	-	%100	%55,95	%44	688	12282	17,9	99
Taşıtlar	SIA	2	7	-	%100	%61,90	%38,1	667	12179	18,3	106
Taşıtlar	SIA	2	8	-	%100	%69,05	%31	701	12226	17,4	104
Taşıtlar	SIA	2	9	-	%100	%67,86	%32,1	670	12073	18	105
Taşıtlar	SIA	3	0	-	%100	%60,00	%40	690	12172	17,6	103
Taşıtlar	SIA	3	1	-	%100	%60,00	%40	689	12480	18,1	96
Taşıtlar	SIA	3	2	-	%100	%67,06	%32,9	692	12543	18,1	105
Taşıtlar	SIA	3	3	-	%100	%67,06	%32,9	686	11973	17,5	90
Taşıtlar	SIA	3	4	-	%100	%65,88	%34,1	706	12291	17,4	109
Taşıtlar	SIA	3	5	-	%100	%57,65	%42,4	670	12441	18,6	106
Taşıtlar	SIA	3	6	-	%100	%55,95	%44	663	12005	18,1	110
Taşıtlar	SIA	3	7	-	%100	%55,95	%44	699	11869	17	117
Taşıtlar	SIA	3	8	-	%100	%67,86	%32,1	702	12051	17,2	104
Taşıtlar	SIA	3	9	-	%100	%72,62	%27,4	710	12349	17,4	113
Taşıtlar	SIA	4	0	-	%100	%65,88	%34,1	675	12687	18,8	115
Taşıtlar	SIA	4	1	-	%100	%61,18	%38,8	697	12194	17,5	116
Taşıtlar	SIA	4	2	-	%100	%63,53	%36,5	675	11761	17,4	104
Taşıtlar	SIA	4	3	-	%100	%65,88	%34,1	689	12378	18	109
Taşıtlar	SIA	4	4	-	%100	%68,24	%31,8	675	11766	17,4	101
Taşıtlar	SIA	4	5	-	%100	%58,82	%41,2	681	12422	18,2	103
Taşıtlar	SIA	4	6	-	%100	%53,57	%46,4	698	11815	16,9	99
Taşıtlar	SIA	4	7	-	%100	%58,33	%41,7	670	12408	18,5	103
Taşıtlar	SIA	4	8	-	%100	%69,05	%31	716	11873	16,6	103
Taşıtlar	SIA	4	9	-	%100	%75,00	%25	671	11974	17,8	100
Taşıtlar	SIA	5	0	-	%100	%63,53	%36,5	675	12597	18,7	101
Taşıtlar	SIA	5	1	-	%100	%55,29	%44,7	684	12438	18,2	98
Taşıtlar	SIA	5	2	-	%100	%63,53	%36,5	690	12480	18,1	98
Taşıtlar	SIA	5	3	-	%100	%61,18	%38,8	681	12710	18,7	99
Taşıtlar	SIA	5	4	-	%100	%62,35	%37,6	692	12625	18,2	93
Taşıtlar	SIA	5	5	-	%100	%51,76	%48,2	696	12610	18,1	97
Taşıtlar	SIA	5	6	-	%100	%52,38	%47,6	664	11871	17,9	82
Taşıtlar	SIA	5	7	-	%100	%58,33	%41,7	675	12623	18,7	81
Taşıtlar	SIA	5	8	-	%100	%70,24	%29,8	711	11908	16,7	92
Taşıtlar	SIA	5	9	-	%100	%58,33	%41,7	668	11859	17,8	84
Wisconsin M. Kans.	ABCMiner	1	0	40.389	%97,14	%94,20	%2,9	2	6	3	8,5
Wisconsin M. Kans.	ABCMiner	1	1	40.316	%97,14	%92,86	%4,3	2	5	2,5	8,6
Wisconsin M. Kans.	ABCMiner	1	2	40.301	%97,62	%92,86	%4,8	2	6	3	8,6
Wisconsin M. Kans.	ABCMiner	1	3	40.348	%97,30	%95,71	%1,6	2	5	2,5	8,3
Wisconsin M. Kans.	ABCMiner	1	4	60.538	%96,98	%98,57	-1,6%	2	6	3	9,3
Wisconsin M. Kans.	ABCMiner	1	5	60.531	%97,30	%97,14	%0,2	2	7	3,5	9,3

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Wisconsin M. Kans.	ABCMiner	1	6	60.457	%96,98	%98,57	-1,6%	2	5	2,5	9,2
Wisconsin M. Kans.	ABCMiner	1	7	60.500	%97,14	%95,71	%1,4	2	6	3	9,4
Wisconsin M. Kans.	ABCMiner	1	8	40.262	%97,30	%95,71	%1,6	2	4	2	8,2
Wisconsin M. Kans.	ABCMiner	1	9	60.521	%96,98	%94,29	%2,7	4	11	2,8	9,2
Wisconsin M. Kans.	ABCMiner	2	0	40.316	%97,14	%94,20	%2,9	2	6	3	8,9
Wisconsin M. Kans.	ABCMiner	2	1	40.294	%97,30	%95,71	%1,6	2	6	3	8,9
Wisconsin M. Kans.	ABCMiner	2	2	40.415	%97,62	%94,29	%3,3	2	7	3,5	8,4
Wisconsin M. Kans.	ABCMiner	2	3	40.339	%97,30	%95,71	%1,6	2	7	3,5	8,9
Wisconsin M. Kans.	ABCMiner	2	4	60.354	%96,82	%100	-3,2%	2	4	2	9,7
Wisconsin M. Kans.	ABCMiner	2	5	60.529	%97,14	%97,14	%0	2	7	3,5	9,4
Wisconsin M. Kans.	ABCMiner	2	6	60.385	%96,98	%98,57	-1,6%	2	5	2,5	9,7
Wisconsin M. Kans.	ABCMiner	2	7	60.496	%97,30	%97,14	%0,2	2	7	3,5	9,4
Wisconsin M. Kans.	ABCMiner	2	8	40.243	%97,30	%95,71	%1,6	2	4	2	8,6
Wisconsin M. Kans.	ABCMiner	2	9	60.398	%96,98	%94,29	%2,7	4	10	2,5	9,4
Wisconsin M. Kans.	ABCMiner	3	0	60.431	%96,35	%95,65	%0,7	4	10	2,5	9,4
Wisconsin M. Kans.	ABCMiner	3	1	40.543	%97,46	%94,29	%3,2	2	7	3,5	8,2
Wisconsin M. Kans.	ABCMiner	3	2	40.303	%97,62	%92,86	%4,8	2	6	3	8,6
Wisconsin M. Kans.	ABCMiner	3	3	40.265	%97,30	%95,71	%1,6	2	5	2,5	8,3
Wisconsin M. Kans.	ABCMiner	3	4	60.664	%96,98	%97,14	-0,2%	2	6	3	9,6
Wisconsin M. Kans.	ABCMiner	3	5	60.559	%97,30	%97,14	%0,2	2	7	3,5	8,6
Wisconsin M. Kans.	ABCMiner	3	6	60.365	%96,98	%98,57	-1,6%	2	4	2	9,6
Wisconsin M. Kans.	ABCMiner	3	7	60.397	%96,98	%97,14	-0,2%	2	5	2,5	8,9
Wisconsin M. Kans.	ABCMiner	3	8	40.230	%97,30	%95,71	%1,6	2	4	2	8,6
Wisconsin M. Kans.	ABCMiner	3	9	60.372	%97,46	%94,29	%3,2	2	5	2,5	9,8
Wisconsin M. Kans.	ABCMiner	4	0	40.288	%97,14	%97,10	%0	2	6	3	8,3
Wisconsin M. Kans.	ABCMiner	4	1	40.265	%97,30	%95,71	%1,6	2	5	2,5	8,4
Wisconsin M. Kans.	ABCMiner	4	2	40.542	%97,62	%94,29	%3,3	2	7	3,5	8,2
Wisconsin M. Kans.	ABCMiner	4	3	40.328	%97,30	%95,71	%1,6	2	7	3,5	8,2
Wisconsin M. Kans.	ABCMiner	4	4	60.522	%96,98	%97,14	-0,2%	2	6	3	8,7
Wisconsin M. Kans.	ABCMiner	4	5	60.449	%97,30	%97,14	%0,2	2	7	3,5	8,9
Wisconsin M. Kans.	ABCMiner	4	6	60.520	%97,14	%98,57	-1,4%	2	7	3,5	9,4
Wisconsin M. Kans.	ABCMiner	4	7	60.483	%97,14	%95,71	%1,4	2	6	3	8,7
Wisconsin M. Kans.	ABCMiner	4	8	40.406	%97,30	%95,71	%1,6	2	6	3	8,2
Wisconsin M. Kans.	ABCMiner	4	9	60.423	%97,46	%94,29	%3,2	2	5	2,5	9,1
Wisconsin M. Kans.	ABCMiner	5	0	40.329	%97,14	%97,10	%0	2	5	2,5	8,3
Wisconsin M. Kans.	ABCMiner	5	1	40.271	%97,30	%95,71	%1,6	2	5	2,5	8
Wisconsin M. Kans.	ABCMiner	5	2	40.369	%97,62	%92,86	%4,8	2	6	3	7,8
Wisconsin M. Kans.	ABCMiner	5	3	40.476	%97,30	%97,14	%0,2	2	7	3,5	8,3
Wisconsin M. Kans.	ABCMiner	5	4	60.427	%96,82	%100	-3,2%	2	5	2,5	9,3
Wisconsin M. Kans.	ABCMiner	5	5	60.530	%97,30	%97,14	%0,2	2	7	3,5	8,7
Wisconsin M. Kans.	ABCMiner	5	6	60.472	%97,14	%98,57	-1,4%	2	6	3	9,3
Wisconsin M. Kans.	ABCMiner	5	7	60.452	%97,30	%97,14	%0,2	2	7	3,5	9,4
Wisconsin M. Kans.	ABCMiner	5	8	40.248	%97,30	%95,71	%1,6	2	4	2	7,8
Wisconsin M. Kans.	ABCMiner	5	9	60.460	%96,98	%94,29	%2,7	4	9	2,3	9,1
Wisconsin M. Kans.	C4.5	-	1	-	%97,94	%95,65	%2,3	10	8	0,8	0,5
Wisconsin M. Kans.	C4.5	-	2	-	%98,41	%92,86	%5,6	15	12	0,8	0,5
Wisconsin M. Kans.	C4.5	-	3	-	%97,46	%98,57	-1,1%	11	9	0,8	0,5
Wisconsin M. Kans.	C4.5	-	4	-	%97,46	%95,71	%1,7	12	9	0,8	0,5
Wisconsin M. Kans.	C4.5	-	5	-	%96,50	%95,71	%0,8	7	7	1	0,5
Wisconsin M. Kans.	C4.5	-	6	-	%97,93	%97,14	%0,8	10	8	0,8	0,5
Wisconsin M. Kans.	C4.5	-	7	-	%96,98	%94,29	%2,7	8	8	1	0,5
Wisconsin M. Kans.	C4.5	-	8	-	%97,46	%95,71	%1,7	11	6	0,5	0,5
Wisconsin M. Kans.	C4.5	-	9	-	%97,14	%95,71	%1,4	8	8	1	0,5
Wisconsin M. Kans.	C4.5	-	10	-	%97,46	%91,43	%6	10	8	0,8	0,5
Wisconsin M. Kans.	CoABCMiner	1	0	110.579	%98,10	%97,10	%1	14	57	4,1	4,5
Wisconsin M. Kans.	CoABCMiner	1	1	110.565	%98,41	%92,86	%5,6	11	44	4	4,5
Wisconsin M. Kans.	CoABCMiner	1	2	110.574	%98,25	%95,71	%2,5	10	48	4,8	4,3
Wisconsin M. Kans.	CoABCMiner	1	3	110.553	%98,25	%95,71	%2,5	12	46	3,8	4,3
Wisconsin M. Kans.	CoABCMiner	1	4	110.557	%98,09	%92,86	%5,2	15	66	4,4	4,4
Wisconsin M. Kans.	CoABCMiner	1	5	110.589	%98,09	%95,71	%2,4	15	56	3,7	4,4
Wisconsin M. Kans.	CoABCMiner	1	6	110.594	%97,93	%98,57	-0,6%	15	59	3,9	4,5
Wisconsin M. Kans.	CoABCMiner	1	7	110.573	%98,09	%98,57	-0,5%	13	50	3,8	4,2
Wisconsin M. Kans.	CoABCMiner	1	8	110.593	%98,09	%95,71	%2,4	12	47	3,9	4,3
Wisconsin M. Kans.	CoABCMiner	1	9	110.564	%98,57	%92,86	%5,7	14	47	3,4	4,6
Wisconsin M. Kans.	CoABCMiner	2	0	110.599	%98,10	%95,65	%2,4	13	48	3,7	4,7
Wisconsin M. Kans.	CoABCMiner	2	1	110.585	%98,09	%90,00	%8,1	11	38	3,5	4,3

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Wisconsin M. Kans.	CoABCMiner	2	2	110.576	%98,09	%95,71	%2,4	15	55	3,7	4,4
Wisconsin M. Kans.	CoABCMiner	2	3	110.571	%98,41	%95,71	%2,7	13	53	4,1	4,5
Wisconsin M. Kans.	CoABCMiner	2	4	110.560	%97,93	%95,71	%2,2	11	43	3,9	4,5
Wisconsin M. Kans.	CoABCMiner	2	5	110.573	%98,09	%95,71	%2,4	15	39	2,6	4,1
Wisconsin M. Kans.	CoABCMiner	2	6	110.586	%97,77	%97,14	%0,6	11	45	4,1	4,5
Wisconsin M. Kans.	CoABCMiner	2	7	110.575	%98,09	%97,14	%0,9	16	58	3,6	4,4
Wisconsin M. Kans.	CoABCMiner	2	8	110.609	%98,09	%95,71	%2,4	13	51	3,9	4,4
Wisconsin M. Kans.	CoABCMiner	2	9	110.593	%98,57	%91,43	%7,1	13	60	4,6	4,6
Wisconsin M. Kans.	CoABCMiner	3	0	110.577	%98,25	%95,65	%2,6	15	54	3,6	4
Wisconsin M. Kans.	CoABCMiner	3	1	110.570	%98,09	%90,00	%8,1	10	41	4,1	4,5
Wisconsin M. Kans.	CoABCMiner	3	2	110.590	%98,25	%98,57	-0,3%	12	38	3,2	4,6
Wisconsin M. Kans.	CoABCMiner	3	3	110.562	%98,25	%95,71	%2,5	12	51	4,3	4,8
Wisconsin M. Kans.	CoABCMiner	3	4	110.568	%98,09	%97,14	%0,9	11	47	4,3	4,5
Wisconsin M. Kans.	CoABCMiner	3	5	110.573	%98,25	%94,29	%4	12	49	4,1	4,7
Wisconsin M. Kans.	CoABCMiner	3	6	110.579	%97,77	%98,57	-0,8%	13	52	4	4,7
Wisconsin M. Kans.	CoABCMiner	3	7	110.585	%98,09	%97,14	%0,9	13	47	3,6	4,6
Wisconsin M. Kans.	CoABCMiner	3	8	110.599	%98,25	%94,29	%4	12	47	3,9	4,5
Wisconsin M. Kans.	CoABCMiner	3	9	110.567	%98,57	%91,43	%7,1	13	59	4,5	4,5
Wisconsin M. Kans.	CoABCMiner	4	0	110.590	%97,94	%92,75	%5,2	14	53	3,8	4,3
Wisconsin M. Kans.	CoABCMiner	4	1	110.585	%98,09	%92,86	%5,2	9	30	3,3	4,3
Wisconsin M. Kans.	CoABCMiner	4	2	110.588	%98,09	%97,14	%0,9	11	37	3,4	4,6
Wisconsin M. Kans.	CoABCMiner	4	3	110.576	%98,09	%95,71	%2,4	13	49	3,8	4,5
Wisconsin M. Kans.	CoABCMiner	4	4	110.577	%98,09	%92,86	%5,2	12	50	4,2	4,5
Wisconsin M. Kans.	CoABCMiner	4	5	110.595	%98,09	%97,14	%0,9	14	55	3,9	4,4
Wisconsin M. Kans.	CoABCMiner	4	6	110.555	%98,09	%98,57	-0,5%	16	69	4,3	4,8
Wisconsin M. Kans.	CoABCMiner	4	7	110.579	%97,93	%98,57	-0,6%	13	52	4	4,5
Wisconsin M. Kans.	CoABCMiner	4	8	110.586	%98,25	%95,71	%2,5	13	54	4,2	4,5
Wisconsin M. Kans.	CoABCMiner	4	9	110.566	%98,41	%94,29	%4,1	13	45	3,5	4,4
Wisconsin M. Kans.	CoABCMiner	5	0	110.581	%98,41	%95,65	%2,8	11	41	3,7	4,4
Wisconsin M. Kans.	CoABCMiner	5	1	110.581	%98,25	%92,86	%5,4	10	43	4,3	4,7
Wisconsin M. Kans.	CoABCMiner	5	2	110.591	%98,25	%97,14	%1,1	14	55	3,9	4,6
Wisconsin M. Kans.	CoABCMiner	5	3	110.576	%98,09	%95,71	%2,4	11	42	3,8	4,5
Wisconsin M. Kans.	CoABCMiner	5	4	110.576	%97,93	%95,71	%2,2	12	43	3,6	4,8
Wisconsin M. Kans.	CoABCMiner	5	5	110.587	%98,25	%94,29	%4	14	54	3,9	4,7
Wisconsin M. Kans.	CoABCMiner	5	6	110.568	%98,41	%98,57	-0,2%	14	59	4,2	4,5
Wisconsin M. Kans.	CoABCMiner	5	7	110.573	%97,93	%97,14	%0,8	16	64	4	4,6
Wisconsin M. Kans.	CoABCMiner	5	8	110.579	%98,41	%92,86	%5,6	13	50	3,8	4,5
Wisconsin M. Kans.	CoABCMiner	5	9	110.574	%98,41	%92,86	%5,6	12	52	4,3	4,6
Wisconsin M. Kans.	CORE	1	0	1.965.625	%98,10	%97,10	%1	8	28	3,5	95,1
Wisconsin M. Kans.	CORE	1	1	1.966.684	%97,93	%92,86	%5,1	4	12	3	96,6
Wisconsin M. Kans.	CORE	1	2	1.965.635	%97,93	%94,29	%3,6	8	23	2,9	92,9
Wisconsin M. Kans.	CORE	1	3	1.966.423	%98,09	%95,71	%2,4	10	32	3,2	97
Wisconsin M. Kans.	CORE	1	4	1.966.752	%97,62	%98,57	-1,0%	4	9	2,3	94
Wisconsin M. Kans.	CORE	1	5	1.965.340	%97,77	%97,14	%0,6	7	16	2,3	92,4
Wisconsin M. Kans.	CORE	1	6	1.964.456	%98,09	%98,57	-0,5%	12	26	2,2	96,4
Wisconsin M. Kans.	CORE	1	7	1.964.156	%97,93	%97,14	%0,8	6	19	3,2	92,2
Wisconsin M. Kans.	CORE	1	8	1.964.871	%98,09	%95,71	%2,4	13	34	2,6	93
Wisconsin M. Kans.	CORE	1	9	1.965.567	%98,25	%94,29	%4	9	29	3,2	95,2
Wisconsin M. Kans.	CORE	2	0	-	%97,78	%94,20	%3,6	7	23	3,3	102,8
Wisconsin M. Kans.	CORE	2	1	-	%98,41	%94,29	%4,1	8	27	3,4	96,9
Wisconsin M. Kans.	CORE	2	2	-	%97,77	%97,14	%0,6	4	8	2	93,6
Wisconsin M. Kans.	CORE	2	3	-	%97,77	%97,14	%0,6	6	15	2,5	98,8
Wisconsin M. Kans.	CORE	2	4	-	%97,62	%94,29	%3,3	4	11	2,8	96,1
Wisconsin M. Kans.	CORE	2	5	-	%97,77	%95,71	%2,1	6	17	2,8	94,7
Wisconsin M. Kans.	CORE	2	6	-	%97,62	%97,14	%0,5	6	12	2	96,2
Wisconsin M. Kans.	CORE	2	7	-	%97,77	%98,57	-0,8%	5	13	2,6	97,8
Wisconsin M. Kans.	CORE	2	8	-	%97,77	%95,71	%2,1	4	10	2,5	94,5
Wisconsin M. Kans.	CORE	2	9	-	%98,25	%94,29	%4	5	16	3,2	98,6
Wisconsin M. Kans.	CORE	3	0	-	%97,94	%94,20	%3,7	6	18	3	100,9
Wisconsin M. Kans.	CORE	3	1	-	%98,09	%94,29	%3,8	13	44	3,4	99,7
Wisconsin M. Kans.	CORE	3	2	-	%97,77	%98,57	-0,8%	8	19	2,4	102,1
Wisconsin M. Kans.	CORE	3	3	-	%97,93	%95,71	%2,2	8	23	2,9	100,4
Wisconsin M. Kans.	CORE	3	4	-	%97,62	%95,71	%1,9	7	23	3,3	99,9
Wisconsin M. Kans.	CORE	3	5	-	%97,93	%97,14	%0,8	7	25	3,6	101,3
Wisconsin M. Kans.	CORE	3	6	-	%97,93	%94,29	%3,6	7	21	3	104,8
Wisconsin M. Kans.	CORE	3	7	-	%97,62	%94,29	%3,3	4	11	2,8	97,9

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Wisconsin M. Kans.	CORE	3	8	-	%98,25	%97,14	%1,1	7	19	2,7	96,5
Wisconsin M. Kans.	CORE	3	9	-	%98,09	%92,86	%5,2	6	19	3,2	100,2
Wisconsin M. Kans.	CORE	4	0	-	%97,78	%95,65	%2,1	5	12	2,4	96
Wisconsin M. Kans.	CORE	4	1	-	%98,09	%92,86	%5,2	6	19	3,2	95,3
Wisconsin M. Kans.	CORE	4	2	-	%97,93	%94,29	%3,6	4	14	3,5	94,3
Wisconsin M. Kans.	CORE	4	3	-	%97,93	%94,29	%3,6	7	21	3	93,8
Wisconsin M. Kans.	CORE	4	4	-	%97,77	%97,14	%0,6	6	22	3,7	96,6
Wisconsin M. Kans.	CORE	4	5	-	%97,93	%94,29	%3,6	10	33	3,3	97,4
Wisconsin M. Kans.	CORE	4	6	-	%97,62	%97,14	%0,5	5	14	2,8	96
Wisconsin M. Kans.	CORE	4	7	-	%97,77	%95,71	%2,1	5	13	2,6	93,8
Wisconsin M. Kans.	CORE	4	8	-	%97,93	%95,71	%2,2	7	20	2,9	98,6
Wisconsin M. Kans.	CORE	4	9	-	%98,25	%94,29	%4	7	18	2,6	97,2
Wisconsin M. Kans.	CORE	5	0	-	%97,94	%92,75	%5,2	6	15	2,5	99,7
Wisconsin M. Kans.	CORE	5	1	-	%98,09	%97,14	%0,9	5	11	2,2	97,7
Wisconsin M. Kans.	CORE	5	2	-	%97,77	%95,71	%2,1	8	31	3,9	100,6
Wisconsin M. Kans.	CORE	5	3	-	%97,93	%98,57	-0,6%	5	13	2,6	97,1
Wisconsin M. Kans.	CORE	5	4	-	%97,62	%98,57	-1,0%	5	13	2,6	99,4
Wisconsin M. Kans.	CORE	5	5	-	%97,77	%95,71	%2,1	5	16	3,2	100,8
Wisconsin M. Kans.	CORE	5	6	-	%97,62	%97,14	%0,5	9	26	2,9	98,8
Wisconsin M. Kans.	CORE	5	7	-	%97,93	%98,57	-0,6%	7	18	2,6	90,3
Wisconsin M. Kans.	CORE	5	8	-	%97,93	%95,71	%2,2	6	19	3,2	100,3
Wisconsin M. Kans.	CORE	5	9	-	%98,41	%91,43	%7	13	44	3,4	98,1
Wisconsin M. Kans.	HIDER	1	0	-	%97,40	%92,50	%4,9	2	6	3	5
Wisconsin M. Kans.	HIDER	1	1	-	%97,90	%91,30	%6,6	3	8	2,7	5
Wisconsin M. Kans.	HIDER	1	2	-	%93,20	%94,20	-1,0%	2	9	4,5	4
Wisconsin M. Kans.	HIDER	1	3	-	%97,40	%97,00	%0,4	3	7	2,3	4
Wisconsin M. Kans.	HIDER	1	4	-	%95,90	%95,50	%0,4	2	8	4	5
Wisconsin M. Kans.	HIDER	1	5	-	%97,10	%98,50	-1,4%	2	4	2	4
Wisconsin M. Kans.	HIDER	1	6	-	%97,20	%98,60	-1,4%	2	6	3	4
Wisconsin M. Kans.	HIDER	1	7	-	%96,90	%100	-3,1%	2	4	2	5
Wisconsin M. Kans.	HIDER	1	8	-	%95,80	%98,60	-2,8%	2	9	4,5	4
Wisconsin M. Kans.	HIDER	1	9	-	%97,70	%92,90	%4,8	2	4	2	4
Wisconsin M. Kans.	HIDER	2	0	-	%97,40	%92,50	%4,9	2	6	3	5
Wisconsin M. Kans.	HIDER	2	1	-	%94,30	%84,10	%10,2	2	8	4	5
Wisconsin M. Kans.	HIDER	2	2	-	%93,20	%94,20	-1,0%	2	9	4,5	4
Wisconsin M. Kans.	HIDER	2	3	-	%93,20	%94,00	-0,8%	2	8	4	4
Wisconsin M. Kans.	HIDER	2	4	-	%96,90	%97,00	-0,1%	2	5	2,5	5
Wisconsin M. Kans.	HIDER	2	5	-	%97,10	%98,50	-1,4%	2	6	3	4
Wisconsin M. Kans.	HIDER	2	6	-	%97,20	%98,60	-1,4%	2	6	3	4
Wisconsin M. Kans.	HIDER	2	7	-	%96,90	%100	-3,1%	2	6	3	5
Wisconsin M. Kans.	HIDER	2	8	-	%95,80	%98,60	-2,8%	2	8	4	4
Wisconsin M. Kans.	HIDER	2	9	-	%97,70	%92,90	%4,8	3	7	2,3	4
Wisconsin M. Kans.	HIDER	3	0	-	%97,40	%92,50	%4,9	3	8	2,7	5
Wisconsin M. Kans.	HIDER	3	1	-	%97,90	%91,30	%6,6	2	6	3	5
Wisconsin M. Kans.	HIDER	3	2	-	%93,20	%94,20	-1,0%	2	9	4,5	4
Wisconsin M. Kans.	HIDER	3	3	-	%97,40	%97,00	%0,4	2	6	3	4
Wisconsin M. Kans.	HIDER	3	4	-	%96,90	%98,50	-1,6%	2	6	3	5
Wisconsin M. Kans.	HIDER	3	5	-	%95,10	%97,10	-2,0%	3	11	3,7	4
Wisconsin M. Kans.	HIDER	3	6	-	%97,20	%98,60	-1,4%	2	6	3	4
Wisconsin M. Kans.	HIDER	3	7	-	%96,90	%100	-3,1%	2	4	2	5
Wisconsin M. Kans.	HIDER	3	8	-	%97,20	%97,10	%0,1	2	4	2	4
Wisconsin M. Kans.	HIDER	3	9	-	%97,70	%92,90	%4,8	2	4	2	4
Wisconsin M. Kans.	HIDER	4	0	-	%97,40	%92,50	%4,9	3	8	2,7	5
Wisconsin M. Kans.	HIDER	4	1	-	%94,30	%84,10	%10,2	2	9	4,5	5
Wisconsin M. Kans.	HIDER	4	2	-	%97,40	%95,70	%1,7	2	7	3,5	4
Wisconsin M. Kans.	HIDER	4	3	-	%97,40	%97,00	%0,4	3	7	2,3	4
Wisconsin M. Kans.	HIDER	4	4	-	%96,90	%97,00	-0,1%	2	5	2,5	5
Wisconsin M. Kans.	HIDER	4	5	-	%97,10	%98,50	-1,4%	2	4	2	4
Wisconsin M. Kans.	HIDER	4	6	-	%97,20	%98,60	-1,4%	2	7	3,5	4
Wisconsin M. Kans.	HIDER	4	7	-	%96,90	%100	-3,1%	2	6	3	5
Wisconsin M. Kans.	HIDER	4	8	-	%97,20	%97,10	%0,1	2	4	2	4
Wisconsin M. Kans.	HIDER	4	9	-	%94,90	%91,40	%3,5	2	6	3	4
Wisconsin M. Kans.	HIDER	5	0	-	%97,40	%92,50	%4,9	2	7	3,5	5
Wisconsin M. Kans.	HIDER	5	1	-	%94,30	%84,10	%10,2	2	9	4,5	5
Wisconsin M. Kans.	HIDER	5	2	-	%93,50	%92,80	%0,7	2	9	4,5	4
Wisconsin M. Kans.	HIDER	5	3	-	%97,40	%97,00	%0,4	3	7	2,3	4

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Wisconsin M. Kans.	HIDER	5	4	-	%94,70	%90,90	%3,8	2	7	3,5	5
Wisconsin M. Kans.	HIDER	5	5	-	%97,10	%98,50	-1,4%	2	7	3,5	4
Wisconsin M. Kans.	HIDER	5	6	-	%97,20	%98,60	-1,4%	3	8	2,7	4
Wisconsin M. Kans.	HIDER	5	7	-	%96,90	%100	-3,1%	2	6	3	5
Wisconsin M. Kans.	HIDER	5	8	-	%97,20	%97,10	%0,1	2	4	2	4
Wisconsin M. Kans.	HIDER	5	9	-	%97,70	%92,90	%4,8	3	6	2	4
Wisconsin M. Kans.	LDWPSO	1	0	40.078	%96,98	%94,20	%2,8	2	5	2,5	15,2
Wisconsin M. Kans.	LDWPSO	1	1	60.163	%97,46	%95,71	%1,7	2	7	3,5	16,5
Wisconsin M. Kans.	LDWPSO	1	2	60.080	%96,98	%95,71	%1,3	2	5	2,5	16,2
Wisconsin M. Kans.	LDWPSO	1	3	60.124	%97,14	%97,14	%0	2	6	3	18,8
Wisconsin M. Kans.	LDWPSO	1	4	60.120	%96,98	%97,14	-0,2%	2	6	3	18,8
Wisconsin M. Kans.	LDWPSO	1	5	60.121	%97,14	%97,14	%0	2	6	3	17,3
Wisconsin M. Kans.	LDWPSO	1	6	60.134	%96,98	%98,57	-1,6%	2	6	3	19,8
Wisconsin M. Kans.	LDWPSO	1	7	60.063	%96,50	%95,71	%0,8	2	4	2	17,6
Wisconsin M. Kans.	LDWPSO	1	8	40.079	%96,98	%95,71	%1,3	2	5	2,5	19,1
Wisconsin M. Kans.	LDWPSO	1	9	60.130	%97,30	%95,71	%1,6	2	6	3	18,2
Wisconsin M. Kans.	LDWPSO	2	0	40.028	%94,29	%89,86	%4,4	3	5	1,7	14
Wisconsin M. Kans.	LDWPSO	2	1	40.023	%95,39	%92,86	%2,5	2	3	1,5	15,6
Wisconsin M. Kans.	LDWPSO	2	2	60.050	%96,66	%94,29	%2,4	4	6	1,5	17,8
Wisconsin M. Kans.	LDWPSO	2	3	60.036	%96,82	%95,71	%1,1	2	4	2	16,4
Wisconsin M. Kans.	LDWPSO	2	4	60.079	%96,66	%100	-3,3%	4	8	2	21
Wisconsin M. Kans.	LDWPSO	2	5	60.054	%96,03	%97,14	-1,1%	4	8	2	20,1
Wisconsin M. Kans.	LDWPSO	2	6	60.055	%96,03	%92,86	%3,2	4	6	1,5	20,3
Wisconsin M. Kans.	LDWPSO	2	7	60.037	%95,39	%94,29	%1,1	4	5	1,3	19,4
Wisconsin M. Kans.	LDWPSO	2	8	60.041	%95,87	%92,86	%3	4	5	1,3	18,1
Wisconsin M. Kans.	LDWPSO	2	9	40.029	%96,98	%92,86	%4,1	3	4	1,3	19,8
Wisconsin M. Kans.	LDWPSO	3	0	40.081	%96,98	%97,10	-0,1%	2	5	2,5	16,5
Wisconsin M. Kans.	LDWPSO	3	1	60.073	%96,50	%92,86	%3,6	4	10	2,5	18,2
Wisconsin M. Kans.	LDWPSO	3	2	60.057	%97,14	%91,43	%5,7	2	4	2	17,3
Wisconsin M. Kans.	LDWPSO	3	3	60.044	%95,39	%95,71	-0,3%	4	7	1,8	17,7
Wisconsin M. Kans.	LDWPSO	3	4	60.091	%96,82	%98,57	-1,8%	2	5	2,5	19
Wisconsin M. Kans.	LDWPSO	3	5	60.113	%96,66	%98,57	-1,9%	2	6	3	18,6
Wisconsin M. Kans.	LDWPSO	3	6	60.069	%96,03	%98,57	-2,5%	2	4	2	17,9
Wisconsin M. Kans.	LDWPSO	3	7	60.061	%96,98	%97,14	-0,2%	2	5	2,5	17,5
Wisconsin M. Kans.	LDWPSO	3	8	60.083	%97,30	%95,71	%1,6	2	4	2	15,8
Wisconsin M. Kans.	LDWPSO	3	9	60.048	%96,34	%92,86	%3,5	4	9	2,3	16,2
Wisconsin M. Kans.	LDWPSO	4	0	40.061	%96,98	%98,55	-1,6%	2	4	2	18
Wisconsin M. Kans.	LDWPSO	4	1	60.106	%97,14	%97,14	%0	2	4	2	18,6
Wisconsin M. Kans.	LDWPSO	4	2	60.220	%97,62	%94,29	%3,3	2	7	3,5	17
Wisconsin M. Kans.	LDWPSO	4	3	60.174	%97,30	%97,14	%0,2	2	6	3	17,1
Wisconsin M. Kans.	LDWPSO	4	4	60.098	%96,98	%97,14	-0,2%	2	6	3	19,2
Wisconsin M. Kans.	LDWPSO	4	5	60.120	%96,98	%97,14	-0,2%	2	5	2,5	17,7
Wisconsin M. Kans.	LDWPSO	4	6	60.085	%96,98	%98,57	-1,6%	2	4	2	15,6
Wisconsin M. Kans.	LDWPSO	4	7	60.060	%97,14	%97,14	%0	2	5	2,5	15,8
Wisconsin M. Kans.	LDWPSO	4	8	40.153	%97,30	%97,14	%0,2	2	6	3	14,2
Wisconsin M. Kans.	LDWPSO	4	9	60.081	%96,34	%94,29	%2,1	4	10	2,5	14
Wisconsin M. Kans.	LDWPSO	5	0	60.061	%95,40	%89,86	%5,5	2	4	2	13,9
Wisconsin M. Kans.	LDWPSO	5	1	40.038	%97,14	%90,00	%7,1	2	4	2	14,5
Wisconsin M. Kans.	LDWPSO	5	2	40.060	%97,30	%95,71	%1,6	2	5	2,5	12,8
Wisconsin M. Kans.	LDWPSO	5	3	40.055	%97,30	%95,71	%1,6	2	5	2,5	13,4
Wisconsin M. Kans.	LDWPSO	5	4	60.095	%96,82	%100	-3,2%	2	5	2,5	14,8
Wisconsin M. Kans.	LDWPSO	5	5	60.155	%96,34	%97,14	-0,8%	4	10	2,5	16
Wisconsin M. Kans.	LDWPSO	5	6	60.052	%96,50	%97,14	-0,6%	4	8	2	14,4
Wisconsin M. Kans.	LDWPSO	5	7	60.107	%97,46	%97,14	%0,3	4	9	2,3	14,2
Wisconsin M. Kans.	LDWPSO	5	8	40.081	%96,34	%94,29	%2,1	2	5	2,5	14,5
Wisconsin M. Kans.	LDWPSO	5	9	60.124	%97,46	%95,71	%1,7	2	6	3	14,4
Wisconsin M. Kans.	PGIRLA	1	0	-	%97,24	%97,01	%0,2	20	66	3,3	2
Wisconsin M. Kans.	PGIRLA	1	1	-	%97,88	%91,30	%6,6	20	65	3,3	2
Wisconsin M. Kans.	PGIRLA	1	2	-	%96,58	%98,55	-2,0%	20	65	3,3	3
Wisconsin M. Kans.	PGIRLA	1	3	-	%95,62	%97,01	-1,4%	20	65	3,3	2
Wisconsin M. Kans.	PGIRLA	1	4	-	%97,24	%98,48	-1,2%	20	65	3,3	2
Wisconsin M. Kans.	PGIRLA	1	5	-	%97,56	%95,59	%2	20	59	3	2
Wisconsin M. Kans.	PGIRLA	1	6	-	%97,23	%97,14	%0,1	20	66	3,3	3
Wisconsin M. Kans.	PGIRLA	1	7	-	%96,26	%97,06	-0,8%	20	59	3	2
Wisconsin M. Kans.	PGIRLA	1	8	-	%98,05	%95,65	%2,4	20	67	3,4	2
Wisconsin M. Kans.	PGIRLA	1	9	-	%98,21	%90,00	%8,2	20	62	3,1	2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Wisconsin M. Kans.	PGIRLA	2	0	-	%97,08	%88,06	%9	20	64	3,2	2
Wisconsin M. Kans.	PGIRLA	2	1	-	%96,74	%92,75	%4	20	69	3,5	2
Wisconsin M. Kans.	PGIRLA	2	2	-	%96,74	%97,10	-0,4%	20	62	3,1	3
Wisconsin M. Kans.	PGIRLA	2	3	-	%97,24	%97,01	%0,2	20	67	3,4	2
Wisconsin M. Kans.	PGIRLA	2	4	-	%97,57	%98,48	-0,9%	20	68	3,4	2
Wisconsin M. Kans.	PGIRLA	2	5	-	%97,40	%97,06	%0,3	20	70	3,5	2
Wisconsin M. Kans.	PGIRLA	2	6	-	%96,08	%98,57	-2,5%	20	57	2,9	3
Wisconsin M. Kans.	PGIRLA	2	7	-	%96,26	%94,12	%2,1	20	58	2,9	2
Wisconsin M. Kans.	PGIRLA	2	8	-	%97,39	%95,65	%1,7	20	54	2,7	2
Wisconsin M. Kans.	PGIRLA	2	9	-	%97,39	%94,29	%3,1	20	63	3,2	2
Wisconsin M. Kans.	PGIRLA	3	0	-	%96,43	%92,54	%3,9	20	73	3,7	2
Wisconsin M. Kans.	PGIRLA	3	1	-	%97,23	%89,86	%7,4	20	72	3,6	2
Wisconsin M. Kans.	PGIRLA	3	2	-	%97,23	%98,55	-1,3%	20	66	3,3	3
Wisconsin M. Kans.	PGIRLA	3	3	-	%97,73	%98,51	-0,8%	20	77	3,9	2
Wisconsin M. Kans.	PGIRLA	3	4	-	%97,08	%95,45	%1,6	20	60	3	2
Wisconsin M. Kans.	PGIRLA	3	5	-	%96,59	%97,06	-0,5%	20	77	3,9	2
Wisconsin M. Kans.	PGIRLA	3	6	-	%97,39	%98,57	-1,2%	20	67	3,4	3
Wisconsin M. Kans.	PGIRLA	3	7	-	%96,91	%94,12	%2,8	20	70	3,5	2
Wisconsin M. Kans.	PGIRLA	3	8	-	%97,23	%95,65	%1,6	20	67	3,4	2
Wisconsin M. Kans.	PGIRLA	3	9	-	%97,55	%92,86	%4,7	20	70	3,5	2
Wisconsin M. Kans.	PGIRLA	4	0	-	%97,24	%95,52	%1,7	20	73	3,7	2
Wisconsin M. Kans.	PGIRLA	4	1	-	%96,91	%88,41	%8,5	20	68	3,4	2
Wisconsin M. Kans.	PGIRLA	4	2	-	%96,74	%97,10	-0,4%	20	63	3,2	3
Wisconsin M. Kans.	PGIRLA	4	3	-	%96,27	%98,51	-2,2%	20	71	3,6	2
Wisconsin M. Kans.	PGIRLA	4	4	-	%96,92	%98,48	-1,6%	20	65	3,3	2
Wisconsin M. Kans.	PGIRLA	4	5	-	%97,40	%98,53	-1,1%	20	73	3,7	2
Wisconsin M. Kans.	PGIRLA	4	6	-	%97,06	%98,57	-1,5%	20	62	3,1	3
Wisconsin M. Kans.	PGIRLA	4	7	-	%97,40	%95,59	%1,8	20	76	3,8	2
Wisconsin M. Kans.	PGIRLA	4	8	-	%97,07	%94,20	%2,9	20	78	3,9	2
Wisconsin M. Kans.	PGIRLA	4	9	-	%97,88	%91,43	%6,5	20	73	3,7	2
Wisconsin M. Kans.	PGIRLA	5	0	-	%96,59	%91,04	%5,5	20	64	3,2	2
Wisconsin M. Kans.	PGIRLA	5	1	-	%98,05	%91,30	%6,7	20	67	3,4	2
Wisconsin M. Kans.	PGIRLA	5	2	-	%97,39	%98,55	-1,2%	20	71	3,6	3
Wisconsin M. Kans.	PGIRLA	5	3	-	%97,24	%98,51	-1,3%	20	69	3,5	2
Wisconsin M. Kans.	PGIRLA	5	4	-	%97,08	%96,97	%0,1	20	69	3,5	2
Wisconsin M. Kans.	PGIRLA	5	5	-	%96,75	%94,12	%2,6	20	56	2,8	2
Wisconsin M. Kans.	PGIRLA	5	6	-	%96,74	%98,57	-1,8%	20	59	3	3
Wisconsin M. Kans.	PGIRLA	5	7	-	%97,07	%98,53	-1,5%	20	55	2,8	2
Wisconsin M. Kans.	PGIRLA	5	8	-	%97,39	%97,10	%0,3	20	68	3,4	2
Wisconsin M. Kans.	PGIRLA	5	9	-	%97,55	%90,00	%7,6	20	70	3,5	2
Wisconsin M. Kans.	SIA	1	0	-	%99,84	%97,10	%2,7	39	164	4,2	7
Wisconsin M. Kans.	SIA	1	1	-	%100	%92,86	%7,1	46	170	3,7	8
Wisconsin M. Kans.	SIA	1	2	-	%99,84	%98,57	%1,3	41	175	4,3	7
Wisconsin M. Kans.	SIA	1	3	-	%99,84	%97,14	%2,7	42	174	4,1	7
Wisconsin M. Kans.	SIA	1	4	-	%99,84	%97,14	%2,7	48	154	3,2	9
Wisconsin M. Kans.	SIA	1	5	-	%99,84	%95,71	%4,1	36	182	5,1	6
Wisconsin M. Kans.	SIA	1	6	-	%99,84	%98,57	%1,3	42	146	3,5	7
Wisconsin M. Kans.	SIA	1	7	-	%99,84	%100	-0,2%	45	142	3,2	8
Wisconsin M. Kans.	SIA	1	8	-	%100	%95,71	%4,3	41	157	3,8	7
Wisconsin M. Kans.	SIA	1	9	-	%99,84	%94,29	%5,6	40	154	3,9	7
Wisconsin M. Kans.	SIA	2	0	-	%100	%92,75	%7,2	44	168	3,8	8
Wisconsin M. Kans.	SIA	2	1	-	%100	%94,29	%5,7	34	161	4,7	7
Wisconsin M. Kans.	SIA	2	2	-	%100	%97,14	%2,9	39	188	4,8	7
Wisconsin M. Kans.	SIA	2	3	-	%99,84	%97,14	%2,7	36	177	4,9	7
Wisconsin M. Kans.	SIA	2	4	-	%100	%95,71	%4,3	46	171	3,7	8
Wisconsin M. Kans.	SIA	2	5	-	%99,84	%92,86	%7	39	163	4,2	7
Wisconsin M. Kans.	SIA	2	6	-	%99,84	%97,14	%2,7	43	146	3,4	8
Wisconsin M. Kans.	SIA	2	7	-	%99,84	%98,57	%1,3	37	165	4,5	7
Wisconsin M. Kans.	SIA	2	8	-	%99,68	%97,14	%2,5	40	158	4	7
Wisconsin M. Kans.	SIA	2	9	-	%100	%91,43	%8,6	41	148	3,6	7
Wisconsin M. Kans.	SIA	3	0	-	%100	%95,65	%4,3	42	216	5,1	9
Wisconsin M. Kans.	SIA	3	1	-	%99,84	%94,29	%5,6	34	206	6,1	7
Wisconsin M. Kans.	SIA	3	2	-	%99,84	%98,57	%1,3	43	186	4,3	8
Wisconsin M. Kans.	SIA	3	3	-	%99,84	%97,14	%2,7	39	187	4,8	7
Wisconsin M. Kans.	SIA	3	4	-	%99,84	%98,57	%1,3	46	208	4,5	9
Wisconsin M. Kans.	SIA	3	5	-	%100	%94,29	%5,7	40	151	3,8	7

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Wisconsin M. Kans.	SIA	3	6	-	%99,84	%98,57	%1,3	42	166	4	8
Wisconsin M. Kans.	SIA	3	7	-	%100	%97,14	%2,9	38	159	4,2	7
Wisconsin M. Kans.	SIA	3	8	-	%99,84	%98,57	%1,3	36	140	3,9	6
Wisconsin M. Kans.	SIA	3	9	-	%99,68	%92,86	%6,8	40	176	4,4	7
Wisconsin M. Kans.	SIA	4	0	-	%99,84	%95,65	%4,2	40	166	4,2	7
Wisconsin M. Kans.	SIA	4	1	-	%100	%92,86	%7,1	38	176	4,6	7
Wisconsin M. Kans.	SIA	4	2	-	%99,68	%97,14	%2,5	42	182	4,3	8
Wisconsin M. Kans.	SIA	4	3	-	%99,84	%97,14	%2,7	38	178	4,7	7
Wisconsin M. Kans.	SIA	4	4	-	%100	%94,29	%5,7	45	215	4,8	8
Wisconsin M. Kans.	SIA	4	5	-	%99,84	%97,14	%2,7	35	201	5,7	6
Wisconsin M. Kans.	SIA	4	6	-	%99,84	%98,57	%1,3	42	144	3,4	7
Wisconsin M. Kans.	SIA	4	7	-	%99,68	%98,57	%1,1	45	166	3,7	7
Wisconsin M. Kans.	SIA	4	8	-	%100	%97,14	%2,9	38	188	4,9	6
Wisconsin M. Kans.	SIA	4	9	-	%99,84	%90,00	%9,8	36	174	4,8	7
Wisconsin M. Kans.	SIA	5	0	-	%99,68	%94,20	%5,5	39	177	4,5	7
Wisconsin M. Kans.	SIA	5	1	-	%99,68	%91,43	%8,3	38	163	4,3	5
Wisconsin M. Kans.	SIA	5	2	-	%99,84	%97,14	%2,7	41	152	3,7	6
Wisconsin M. Kans.	SIA	5	3	-	%99,84	%95,71	%4,1	37	157	4,2	6
Wisconsin M. Kans.	SIA	5	4	-	%99,84	%95,71	%4,1	47	150	3,2	7
Wisconsin M. Kans.	SIA	5	5	-	%99,84	%97,14	%2,7	38	149	3,9	5
Wisconsin M. Kans.	SIA	5	6	-	%99,84	%98,57	%1,3	45	172	3,8	6
Wisconsin M. Kans.	SIA	5	7	-	%99,68	%97,14	%2,5	40	165	4,1	6
Wisconsin M. Kans.	SIA	5	8	-	%100	%97,14	%2,9	37	148	4	6
Wisconsin M. Kans.	SIA	5	9	-	%99,68	%91,43	%8,3	39	158	4,1	7
Yeni Tiroid	ABCMiner	1	0	60.370	%97,93	%86,36	%11,6	4	7	1,8	5,2
Yeni Tiroid	ABCMiner	1	1	60.368	%98,45	%54,55	%43,9	4	7	1,8	5,5
Yeni Tiroid	ABCMiner	1	2	38.501	%100	%59,09	%40,9	4	6	1,5	4,2
Yeni Tiroid	ABCMiner	1	3	40.865	%97,93	%90,91	%7	4	8	2	4,4
Yeni Tiroid	ABCMiner	1	4	60.352	%98,45	%90,91	%7,5	4	7	1,8	5,5
Yeni Tiroid	ABCMiner	1	5	44.735	%97,42	%90,48	%6,9	4	6	1,5	4,7
Yeni Tiroid	ABCMiner	1	6	44.575	%99,48	%90,48	%9	4	8	2	4,3
Yeni Tiroid	ABCMiner	1	7	42.600	%98,45	%76,19	%22,3	4	6	1,5	4,3
Yeni Tiroid	ABCMiner	1	8	44.502	%98,45	%80,95	%17,5	4	7	1,8	4,6
Yeni Tiroid	ABCMiner	1	9	41.395	%97,94	%76,19	%21,7	4	8	2	4,1
Yeni Tiroid	ABCMiner	2	0	60.364	%97,93	%86,36	%11,6	4	7	1,8	5,5
Yeni Tiroid	ABCMiner	2	1	40.536	%97,93	%45,45	%52,5	4	7	1,8	4,3
Yeni Tiroid	ABCMiner	2	2	44.117	%99,48	%68,18	%31,3	4	9	2,3	4,7
Yeni Tiroid	ABCMiner	2	3	60.373	%97,93	%100	-2,1%	4	7	1,8	5,5
Yeni Tiroid	ABCMiner	2	4	41.585	%98,45	%95,45	%3	4	7	1,8	4,3
Yeni Tiroid	ABCMiner	2	5	50.817	%98,97	%95,24	%3,7	4	7	1,8	5,1
Yeni Tiroid	ABCMiner	2	6	43.317	%96,91	%80,95	%16	4	7	1,8	4,3
Yeni Tiroid	ABCMiner	2	7	60.371	%97,94	%71,43	%26,5	4	6	1,5	5,6
Yeni Tiroid	ABCMiner	2	8	46.899	%97,94	%90,48	%7,5	4	6	1,5	4,6
Yeni Tiroid	ABCMiner	2	9	43.401	%99,48	%90,48	%9	4	9	2,3	4,6
Yeni Tiroid	ABCMiner	3	0	54.858	%98,96	%95,45	%3,5	4	8	2	5,1
Yeni Tiroid	ABCMiner	3	1	41.256	%99,48	%45,45	%54	4	8	2	4,3
Yeni Tiroid	ABCMiner	3	2	21.317	%99,48	%77,27	%22,2	4	5	1,3	3,8
Yeni Tiroid	ABCMiner	3	3	55.710	%97,41	%72,73	%24,7	4	5	1,3	5
Yeni Tiroid	ABCMiner	3	4	60.369	%97,93	%90,91	%7	4	4	1	5,5
Yeni Tiroid	ABCMiner	3	5	40.452	%98,45	%52,38	%46,1	4	8	2	4,5
Yeni Tiroid	ABCMiner	3	6	40.993	%98,97	%85,71	%13,3	4	7	1,8	4,4
Yeni Tiroid	ABCMiner	3	7	53.267	%97,42	%52,38	%45	4	6	1,5	5,1
Yeni Tiroid	ABCMiner	3	8	60.390	%98,45	%85,71	%12,7	4	7	1,8	5,6
Yeni Tiroid	ABCMiner	3	9	50.576	%97,94	%85,71	%12,2	4	6	1,5	4,8
Yeni Tiroid	ABCMiner	4	0	60.375	%98,45	%90,91	%7,5	4	8	2	5,2
Yeni Tiroid	ABCMiner	4	1	42.066	%98,45	%50,00	%48,4	4	8	2	4,3
Yeni Tiroid	ABCMiner	4	2	24.913	%100	%77,27	%22,7	4	6	1,5	3,6
Yeni Tiroid	ABCMiner	4	3	50.129	%97,41	%77,27	%20,1	4	6	1,5	4,5
Yeni Tiroid	ABCMiner	4	4	60.363	%97,41	%86,36	%11	4	5	1,3	5,2
Yeni Tiroid	ABCMiner	4	5	40.466	%97,94	%66,67	%31,3	4	8	2	4,2
Yeni Tiroid	ABCMiner	4	6	44.910	%97,42	%80,95	%16,5	4	7	1,8	4,4
Yeni Tiroid	ABCMiner	4	7	40.461	%96,91	%71,43	%25,5	4	7	1,8	3,9
Yeni Tiroid	ABCMiner	4	8	40.472	%98,45	%90,48	%8	4	7	1,8	4,1
Yeni Tiroid	ABCMiner	4	9	44.129	%98,45	%85,71	%12,7	4	8	2	4,2
Yeni Tiroid	ABCMiner	5	0	47.095	%97,93	%90,91	%7	4	6	1,5	4,5
Yeni Tiroid	ABCMiner	5	1	44.304	%97,93	%59,09	%38,8	4	8	2	4,2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Yeni Tiroid	ABCMiner	5	2	54.342	%97,41	%77,27	%20,1	4	6	1,5	5
Yeni Tiroid	ABCMiner	5	3	40.340	%96,89	%68,18	%28,7	4	5	1,3	4
Yeni Tiroid	ABCMiner	5	4	46.795	%98,45	%86,36	%12,1	4	7	1,8	4,4
Yeni Tiroid	ABCMiner	5	5	47.631	%97,42	%95,24	%2,2	4	6	1,5	4,5
Yeni Tiroid	ABCMiner	5	6	60.364	%97,42	%90,48	%6,9	4	6	1,5	5,3
Yeni Tiroid	ABCMiner	5	7	60.376	%97,42	%76,19	%21,2	4	6	1,5	5
Yeni Tiroid	ABCMiner	5	8	60.360	%98,45	%85,71	%12,7	4	8	2	5,3
Yeni Tiroid	ABCMiner	5	9	46.587	%99,48	%76,19	%23,3	4	10	2,5	4,5
Yeni Tiroid	C4.5	-	1	-	%98,96	%90,91	%8,1	6	6	1	0,3
Yeni Tiroid	C4.5	-	2	-	%92,75	%81,82	%10,9	5	6	1,2	0,3
Yeni Tiroid	C4.5	-	3	-	%98,45	%86,36	%12,1	6	6	1	0,3
Yeni Tiroid	C4.5	-	4	-	%94,30	%81,82	%12,5	5	6	1,2	0,3
Yeni Tiroid	C4.5	-	5	-	%97,41	%90,91	%6,5	6	6	1	0,3
Yeni Tiroid	C4.5	-	6	-	%97,94	%95,24	%2,7	6	7	1,2	0,3
Yeni Tiroid	C4.5	-	7	-	%98,45	%90,48	%8	6	5	0,8	0,3
Yeni Tiroid	C4.5	-	8	-	%97,42	%95,24	%2,2	5	5	1	0,3
Yeni Tiroid	C4.5	-	9	-	%96,91	%100	-3,1%	5	5	1	0,3
Yeni Tiroid	C4.5	-	10	-	%97,42	%90,48	%6,9	6	6	1	0,3
Yeni Tiroid	CoABCMiner	1	0	110.542	%97,93	%90,91	%7	4	17	4,3	1,2
Yeni Tiroid	CoABCMiner	1	1	110.528	%98,96	%90,91	%8,1	6	27	4,5	1,3
Yeni Tiroid	CoABCMiner	1	2	110.529	%97,93	%81,82	%16,1	5	19	3,8	1,3
Yeni Tiroid	CoABCMiner	1	3	110.518	%97,93	%100	-2,1%	5	20	4	1,3
Yeni Tiroid	CoABCMiner	1	4	110.544	%97,93	%90,91	%7	5	16	3,2	1,3
Yeni Tiroid	CoABCMiner	1	5	110.523	%98,97	%95,24	%3,7	5	18	3,6	1,3
Yeni Tiroid	CoABCMiner	1	6	110.542	%97,42	%90,48	%6,9	6	20	3,3	1,3
Yeni Tiroid	CoABCMiner	1	7	110.544	%98,45	%90,48	%8	6	24	4	1,3
Yeni Tiroid	CoABCMiner	1	8	110.521	%97,42	%100	-2,6%	9	41	4,6	1,4
Yeni Tiroid	CoABCMiner	1	9	110.522	%97,42	%95,24	%2,2	6	22	3,7	1,3
Yeni Tiroid	CoABCMiner	2	0	110.548	%97,93	%90,91	%7	5	19	3,8	1,3
Yeni Tiroid	CoABCMiner	2	1	110.538	%98,45	%100	-1,6%	8	36	4,5	1,3
Yeni Tiroid	CoABCMiner	2	2	110.538	%98,96	%86,36	%12,6	5	22	4,4	1,3
Yeni Tiroid	CoABCMiner	2	3	110.527	%97,41	%95,45	%2	7	24	3,4	1,3
Yeni Tiroid	CoABCMiner	2	4	110.553	%98,96	%90,91	%8,1	5	19	3,8	1,3
Yeni Tiroid	CoABCMiner	2	5	110.540	%97,42	%90,48	%6,9	6	17	2,8	1,4
Yeni Tiroid	CoABCMiner	2	6	110.536	%96,91	%85,71	%11,2	8	30	3,8	1,2
Yeni Tiroid	CoABCMiner	2	7	110.538	%97,94	%95,24	%2,7	5	17	3,4	1,1
Yeni Tiroid	CoABCMiner	2	8	110.520	%96,91	%100	-3,1%	6	17	2,8	1,2
Yeni Tiroid	CoABCMiner	2	9	110.520	%96,91	%85,71	%11,2	7	31	4,4	1,2
Yeni Tiroid	CoABCMiner	3	0	110.525	%97,41	%95,45	%2	6	22	3,7	1
Yeni Tiroid	CoABCMiner	3	1	110.512	%98,96	%95,45	%3,5	7	28	4	1,1
Yeni Tiroid	CoABCMiner	3	2	110.528	%98,96	%86,36	%12,6	6	20	3,3	1,2
Yeni Tiroid	CoABCMiner	3	3	110.535	%97,93	%100	-2,1%	6	22	3,7	1,1
Yeni Tiroid	CoABCMiner	3	4	110.540	%97,93	%90,91	%7	6	22	3,7	1,1
Yeni Tiroid	CoABCMiner	3	5	110.532	%97,94	%95,24	%2,7	5	18	3,6	1,1
Yeni Tiroid	CoABCMiner	3	6	110.536	%98,45	%85,71	%12,7	5	20	4	1,1
Yeni Tiroid	CoABCMiner	3	7	110.528	%97,94	%95,24	%2,7	5	19	3,8	1,2
Yeni Tiroid	CoABCMiner	3	8	110.514	%97,42	%100	-2,6%	5	18	3,6	1,2
Yeni Tiroid	CoABCMiner	3	9	110.517	%96,91	%100	-3,1%	8	31	3,9	1,1
Yeni Tiroid	CoABCMiner	4	0	110.537	%97,93	%95,45	%2,5	6	20	3,3	1,1
Yeni Tiroid	CoABCMiner	4	1	110.530	%97,93	%90,91	%7	8	34	4,3	1,1
Yeni Tiroid	CoABCMiner	4	2	110.511	%98,96	%86,36	%12,6	7	29	4,1	1,2
Yeni Tiroid	CoABCMiner	4	3	110.528	%98,45	%95,45	%3	9	33	3,7	1,2
Yeni Tiroid	CoABCMiner	4	4	110.543	%97,93	%90,91	%7	5	14	2,8	1,2
Yeni Tiroid	CoABCMiner	4	5	110.523	%98,45	%95,24	%3,2	6	21	3,5	1,1
Yeni Tiroid	CoABCMiner	4	6	110.521	%97,94	%95,24	%2,7	6	20	3,3	1,1
Yeni Tiroid	CoABCMiner	4	7	110.543	%98,45	%100	-1,5%	7	27	3,9	1
Yeni Tiroid	CoABCMiner	4	8	110.533	%97,42	%100	-2,6%	9	33	3,7	1,2
Yeni Tiroid	CoABCMiner	4	9	110.527	%97,42	%95,24	%2,2	8	33	4,1	1,1
Yeni Tiroid	CoABCMiner	5	0	110.530	%97,93	%95,45	%2,5	7	29	4,1	1,1
Yeni Tiroid	CoABCMiner	5	1	110.527	%98,45	%100	-1,6%	8	31	3,9	1,1
Yeni Tiroid	CoABCMiner	5	2	110.538	%98,96	%86,36	%12,6	7	28	4	1,2
Yeni Tiroid	CoABCMiner	5	3	110.543	%97,93	%100	-2,1%	5	19	3,8	1,2
Yeni Tiroid	CoABCMiner	5	4	110.542	%98,45	%90,91	%7,5	6	22	3,7	1,2
Yeni Tiroid	CoABCMiner	5	5	110.543	%98,45	%95,24	%3,2	6	23	3,8	1,1
Yeni Tiroid	CoABCMiner	5	6	110.531	%97,94	%95,24	%2,7	7	22	3,1	1,1
Yeni Tiroid	CoABCMiner	5	7	110.554	%97,94	%95,24	%2,7	6	21	3,5	1,1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Yeni Tiroid	CoABCMiner	5	8	110.532	%97,94	%100	-2,1%	8	31	3,9	1,2
Yeni Tiroid	CoABCMiner	5	9	110.514	%96,39	%80,95	%15,4	5	22	4,4	1,1
Yeni Tiroid	CORE	1	0	1.964.566	%96,37	%86,36	%10	6	12	2	29,4
Yeni Tiroid	CORE	1	1	1.963.460	%97,93	%86,36	%11,6	7	17	2,4	31,1
Yeni Tiroid	CORE	1	2	1.963.532	%98,96	%86,36	%12,6	5	11	2,2	31,2
Yeni Tiroid	CORE	1	3	1.962.981	%97,93	%95,45	%2,5	5	10	2	28,6
Yeni Tiroid	CORE	1	4	1.962.122	%98,45	%100	-1,6%	11	31	2,8	30,3
Yeni Tiroid	CORE	1	5	1.964.254	%97,42	%95,24	%2,2	5	12	2,4	30,8
Yeni Tiroid	CORE	1	6	1.961.331	%98,45	%95,24	%3,2	7	13	1,9	31
Yeni Tiroid	CORE	1	7	1.964.268	%97,42	%90,48	%6,9	5	11	2,2	30,7
Yeni Tiroid	CORE	1	8	1.964.769	%96,91	%100	-3,1%	7	14	2	31,1
Yeni Tiroid	CORE	1	9	1.965.057	%97,94	%85,71	%12,2	9	22	2,4	30,8
Yeni Tiroid	CORE	2	0	-	%97,41	%90,91	%6,5	6	13	2,2	31
Yeni Tiroid	CORE	2	1	-	%98,45	%100	-1,6%	11	27	2,5	30,3
Yeni Tiroid	CORE	2	2	-	%98,96	%86,36	%12,6	5	15	3	31,7
Yeni Tiroid	CORE	2	3	-	%97,93	%100	-2,1%	5	16	3,2	29,8
Yeni Tiroid	CORE	2	4	-	%97,93	%90,91	%7	6	14	2,3	32,7
Yeni Tiroid	CORE	2	5	-	%96,39	%95,24	%1,2	4	6	1,5	31,4
Yeni Tiroid	CORE	2	6	-	%97,94	%90,48	%7,5	6	16	2,7	28,3
Yeni Tiroid	CORE	2	7	-	%98,45	%90,48	%8	7	20	2,9	28,8
Yeni Tiroid	CORE	2	8	-	%97,42	%90,48	%6,9	6	16	2,7	30,4
Yeni Tiroid	CORE	2	9	-	%95,88	%95,24	%0,6	4	9	2,3	30,7
Yeni Tiroid	CORE	3	0	-	%97,41	%95,45	%2	5	15	3	27,1
Yeni Tiroid	CORE	3	1	-	%97,93	%100	-2,1%	7	22	3,1	32
Yeni Tiroid	CORE	3	2	-	%98,96	%86,36	%12,6	5	11	2,2	29,7
Yeni Tiroid	CORE	3	3	-	%99,48	%86,36	%13,1	8	19	2,4	30,3
Yeni Tiroid	CORE	3	4	-	%97,93	%90,91	%7	5	11	2,2	31,4
Yeni Tiroid	CORE	3	5	-	%97,94	%100	-2,1%	7	14	2	31
Yeni Tiroid	CORE	3	6	-	%97,94	%90,48	%7,5	5	13	2,6	30,2
Yeni Tiroid	CORE	3	7	-	%97,42	%95,24	%2,2	4	10	2,5	29,5
Yeni Tiroid	CORE	3	8	-	%97,94	%100	-2,1%	12	30	2,5	30,6
Yeni Tiroid	CORE	3	9	-	%97,94	%90,48	%7,5	6	13	2,2	30,7
Yeni Tiroid	CORE	4	0	-	%97,93	%90,91	%7	5	9	1,8	29,3
Yeni Tiroid	CORE	4	1	-	%96,89	%100	-3,1%	6	13	2,2	30,7
Yeni Tiroid	CORE	4	2	-	%98,45	%86,36	%12,1	5	13	2,6	27,9
Yeni Tiroid	CORE	4	3	-	%97,41	%90,91	%6,5	4	10	2,5	31,7
Yeni Tiroid	CORE	4	4	-	%96,37	%95,45	%0,9	5	13	2,6	26
Yeni Tiroid	CORE	4	5	-	%97,94	%95,24	%2,7	6	20	3,3	30,5
Yeni Tiroid	CORE	4	6	-	%97,94	%90,48	%7,5	5	13	2,6	28
Yeni Tiroid	CORE	4	7	-	%98,45	%95,24	%3,2	11	20	1,8	31,6
Yeni Tiroid	CORE	4	8	-	%96,91	%100	-3,1%	6	16	2,7	29,8
Yeni Tiroid	CORE	4	9	-	%98,97	%100	-1,0%	8	15	1,9	31,4
Yeni Tiroid	CORE	5	0	-	%96,89	%90,91	%6	6	11	1,8	30,1
Yeni Tiroid	CORE	5	1	-	%98,45	%100	-1,6%	12	26	2,2	31,5
Yeni Tiroid	CORE	5	2	-	%98,45	%86,36	%12,1	5	11	2,2	34,4
Yeni Tiroid	CORE	5	3	-	%97,41	%90,91	%6,5	3	9	3	31,9
Yeni Tiroid	CORE	5	4	-	%98,45	%95,45	%3	14	23	1,6	30,2
Yeni Tiroid	CORE	5	5	-	%97,94	%95,24	%2,7	6	11	1,8	33,3
Yeni Tiroid	CORE	5	6	-	%97,42	%90,48	%6,9	7	21	3	29,1
Yeni Tiroid	CORE	5	7	-	%97,42	%95,24	%2,2	5	11	2,2	31
Yeni Tiroid	CORE	5	8	-	%96,39	%95,24	%1,2	5	10	2	29,4
Yeni Tiroid	CORE	5	9	-	%95,88	%100	-4,1%	5	12	2,4	31
Yeni Tiroid	HIDER	1	0	-	%93,80	%95,50	-1,7%	3	15	5	2
Yeni Tiroid	HIDER	1	1	-	%93,80	%86,40	%7,4	3	14	4,7	2
Yeni Tiroid	HIDER	1	2	-	%95,90	%100	-4,1%	3	14	4,7	2
Yeni Tiroid	HIDER	1	3	-	%96,40	%77,30	%19,1	3	13	4,3	2
Yeni Tiroid	HIDER	1	4	-	%93,80	%90,90	%2,9	3	15	5	1
Yeni Tiroid	HIDER	1	5	-	%94,30	%100	-5,7%	4	20	5	2
Yeni Tiroid	HIDER	1	6	-	%94,30	%81,00	%13,3	3	14	4,7	2
Yeni Tiroid	HIDER	1	7	-	%95,90	%85,70	%10,2	4	19	4,8	2
Yeni Tiroid	HIDER	1	8	-	%93,80	%95,20	-1,4%	3	13	4,3	2
Yeni Tiroid	HIDER	1	9	-	%91,20	%85,70	%5,5	3	13	4,3	2
Yeni Tiroid	HIDER	2	0	-	%93,30	%95,50	-2,2%	3	14	4,7	2
Yeni Tiroid	HIDER	2	1	-	%94,30	%86,40	%7,9	3	14	4,7	2
Yeni Tiroid	HIDER	2	2	-	%94,80	%90,90	%3,9	4	20	5	2
Yeni Tiroid	HIDER	2	3	-	%93,80	%81,80	%12	3	12	4	2

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Yeni Tiroid	HIDER	2	4	-	%92,70	%95,50	-2,8%	3	15	5	1
Yeni Tiroid	HIDER	2	5	-	%92,80	%100	-7,2%	3	16	5,3	2
Yeni Tiroid	HIDER	2	6	-	%95,90	%85,70	%10,2	3	12	4	2
Yeni Tiroid	HIDER	2	7	-	%93,30	%90,50	%2,8	3	14	4,7	2
Yeni Tiroid	HIDER	2	8	-	%93,30	%100	-6,7%	4	20	5	2
Yeni Tiroid	HIDER	2	9	-	%93,30	%95,20	-1,9%	3	16	5,3	2
Yeni Tiroid	HIDER	3	0	-	%94,80	%95,50	-0,7%	3	14	4,7	2
Yeni Tiroid	HIDER	3	1	-	%94,30	%86,40	%7,9	3	13	4,3	2
Yeni Tiroid	HIDER	3	2	-	%96,40	%95,50	%0,9	4	18	4,5	2
Yeni Tiroid	HIDER	3	3	-	%94,80	%77,30	%17,5	3	16	5,3	2
Yeni Tiroid	HIDER	3	4	-	%93,80	%90,90	%2,9	3	14	4,7	1
Yeni Tiroid	HIDER	3	5	-	%91,80	%100	-8,2%	3	15	5	2
Yeni Tiroid	HIDER	3	6	-	%95,40	%90,50	%4,9	3	15	5	2
Yeni Tiroid	HIDER	3	7	-	%94,30	%85,70	%8,6	3	14	4,7	2
Yeni Tiroid	HIDER	3	8	-	%95,40	%95,20	%0,2	4	17	4,3	2
Yeni Tiroid	HIDER	3	9	-	%93,80	%85,70	%8,1	3	12	4	2
Yeni Tiroid	HIDER	4	0	-	%95,30	%90,90	%4,4	4	18	4,5	2
Yeni Tiroid	HIDER	4	1	-	%95,90	%86,40	%9,5	4	17	4,3	2
Yeni Tiroid	HIDER	4	2	-	%93,30	%95,50	-2,2%	3	15	5	2
Yeni Tiroid	HIDER	4	3	-	%95,90	%81,80	%14,1	3	15	5	2
Yeni Tiroid	HIDER	4	4	-	%94,30	%90,90	%3,4	3	16	5,3	1
Yeni Tiroid	HIDER	4	5	-	%91,80	%100	-8,2%	3	16	5,3	2
Yeni Tiroid	HIDER	4	6	-	%94,80	%90,50	%4,3	3	12	4	2
Yeni Tiroid	HIDER	4	7	-	%95,90	%85,70	%10,2	4	18	4,5	2
Yeni Tiroid	HIDER	4	8	-	%92,80	%100	-7,2%	3	13	4,3	2
Yeni Tiroid	HIDER	4	9	-	%94,30	%95,20	-0,9%	4	20	5	2
Yeni Tiroid	HIDER	5	0	-	%95,30	%90,90	%4,4	4	20	5	2
Yeni Tiroid	HIDER	5	1	-	%95,90	%81,80	%14,1	4	16	4	2
Yeni Tiroid	HIDER	5	2	-	%92,70	%90,90	%1,8	3	14	4,7	2
Yeni Tiroid	HIDER	5	3	-	%96,40	%81,80	%14,6	3	13	4,3	2
Yeni Tiroid	HIDER	5	4	-	%94,30	%86,40	%7,9	3	15	5	1
Yeni Tiroid	HIDER	5	5	-	%94,80	%100	-5,2%	4	19	4,8	2
Yeni Tiroid	HIDER	5	6	-	%95,90	%81,00	%14,9	3	13	4,3	2
Yeni Tiroid	HIDER	5	7	-	%95,40	%90,50	%4,9	4	19	4,8	2
Yeni Tiroid	HIDER	5	8	-	%94,80	%95,20	-0,4%	3	13	4,3	2
Yeni Tiroid	HIDER	5	9	-	%93,80	%85,70	%8,1	3	14	4,7	2
Yeni Tiroid	LDWPSO	1	0	60.021	%95,85	%90,91	%4,9	4	5	1,3	7,1
Yeni Tiroid	LDWPSO	1	1	60.035	%96,37	%45,45	%50,9	4	7	1,8	7,8
Yeni Tiroid	LDWPSO	1	2	60.031	%97,41	%90,91	%6,5	4	7	1,8	7,7
Yeni Tiroid	LDWPSO	1	3	60.030	%96,37	%95,45	%0,9	4	6	1,5	9,1
Yeni Tiroid	LDWPSO	1	4	60.029	%96,37	%90,91	%5,5	4	5	1,3	8,2
Yeni Tiroid	LDWPSO	1	5	60.027	%95,36	%76,19	%19,2	4	6	1,5	8,4
Yeni Tiroid	LDWPSO	1	6	60.029	%94,85	%90,48	%4,4	4	4	1	8,5
Yeni Tiroid	LDWPSO	1	7	60.024	%95,36	%90,48	%4,9	4	4	1	7,9
Yeni Tiroid	LDWPSO	1	8	60.032	%94,85	%90,48	%4,4	4	5	1,3	8,7
Yeni Tiroid	LDWPSO	1	9	60.034	%96,91	%47,62	%49,3	4	6	1,5	8,7
Yeni Tiroid	LDWPSO	2	0	60.026	%97,93	%81,82	%16,1	4	5	1,3	7,9
Yeni Tiroid	LDWPSO	2	1	60.027	%97,93	%90,91	%7	4	5	1,3	8
Yeni Tiroid	LDWPSO	2	2	60.025	%100	%68,18	%31,8	4	6	1,5	7,9
Yeni Tiroid	LDWPSO	2	3	60.027	%96,89	%86,36	%10,5	4	6	1,5	8,2
Yeni Tiroid	LDWPSO	2	4	60.031	%95,34	%86,36	%9	4	5	1,3	9,9
Yeni Tiroid	LDWPSO	2	5	60.023	%95,88	%71,43	%24,4	4	6	1,5	8,2
Yeni Tiroid	LDWPSO	2	6	60.020	%95,88	%90,48	%5,4	4	5	1,3	8,9
Yeni Tiroid	LDWPSO	2	7	60.021	%94,85	%76,19	%18,7	4	4	1	9,6
Yeni Tiroid	LDWPSO	2	8	60.025	%97,94	%80,95	%17	4	5	1,3	9,7
Yeni Tiroid	LDWPSO	2	9	60.025	%96,91	%42,86	%54,1	4	5	1,3	10,5
Yeni Tiroid	LDWPSO	3	0	60.032	%96,89	%86,36	%10,5	4	6	1,5	8
Yeni Tiroid	LDWPSO	3	1	60.030	%97,93	%86,36	%11,6	4	5	1,3	10,2
Yeni Tiroid	LDWPSO	3	2	60.030	%97,41	%90,91	%6,5	4	7	1,8	8,4
Yeni Tiroid	LDWPSO	3	3	60.032	%96,37	%77,27	%19,1	4	6	1,5	9
Yeni Tiroid	LDWPSO	3	4	60.032	%97,41	%86,36	%11	4	6	1,5	8,4
Yeni Tiroid	LDWPSO	3	5	60.027	%96,39	%76,19	%20,2	4	6	1,5	8,6
Yeni Tiroid	LDWPSO	3	6	60.034	%97,42	%76,19	%21,2	4	6	1,5	8,1
Yeni Tiroid	LDWPSO	3	7	60.029	%95,88	%85,71	%10,2	4	5	1,3	7,6
Yeni Tiroid	LDWPSO	3	8	60.027	%95,36	%90,48	%4,9	4	5	1,3	7,8
Yeni Tiroid	LDWPSO	3	9	60.036	%95,88	%85,71	%10,2	4	6	1,5	7,5

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Yeni Tiroid	LDWPSO	4	0	60.032	%97,41	%86,36	%11	4	6	1,5	9,2
Yeni Tiroid	LDWPSO	4	1	60.035	%96,89	%59,09	%37,8	4	6	1,5	8,4
Yeni Tiroid	LDWPSO	4	2	60.042	%95,34	%95,45	-0,1%	4	7	1,8	8,3
Yeni Tiroid	LDWPSO	4	3	60.029	%96,37	%95,45	%0,9	4	6	1,5	8,7
Yeni Tiroid	LDWPSO	4	4	60.034	%96,37	%72,73	%23,6	4	6	1,5	8,5
Yeni Tiroid	LDWPSO	4	5	60.031	%95,36	%71,43	%23,9	4	6	1,5	8,5
Yeni Tiroid	LDWPSO	4	6	60.023	%96,39	%95,24	%1,2	4	6	1,5	7,6
Yeni Tiroid	LDWPSO	4	7	60.040	%96,91	%61,90	%35	4	7	1,8	8,1
Yeni Tiroid	LDWPSO	4	8	60.035	%97,42	%76,19	%21,2	4	8	2	6,9
Yeni Tiroid	LDWPSO	4	9	60.037	%96,91	%57,14	%39,8	4	7	1,8	7,2
Yeni Tiroid	LDWPSO	5	0	60.020	%95,85	%90,91	%4,9	4	5	1,3	6,9
Yeni Tiroid	LDWPSO	5	1	60.016	%94,82	%63,64	%31,2	4	5	1,3	6,7
Yeni Tiroid	LDWPSO	5	2	60.026	%97,93	%77,27	%20,7	4	6	1,5	6,7
Yeni Tiroid	LDWPSO	5	3	60.017	%94,82	%90,91	%3,9	4	6	1,5	6,7
Yeni Tiroid	LDWPSO	5	4	60.017	%95,85	%86,36	%9,5	4	6	1,5	6,6
Yeni Tiroid	LDWPSO	5	5	60.020	%97,42	%90,48	%6,9	4	6	1,5	7,1
Yeni Tiroid	LDWPSO	5	6	60.023	%97,42	%76,19	%21,2	4	6	1,5	6,6
Yeni Tiroid	LDWPSO	5	7	60.026	%96,39	%85,71	%10,7	4	5	1,3	6,8
Yeni Tiroid	LDWPSO	5	8	60.024	%96,39	%80,95	%15,4	4	6	1,5	6,6
Yeni Tiroid	LDWPSO	5	9	60.023	%96,39	%80,95	%15,4	4	6	1,5	6,6
Yeni Tiroid	PGIRLA	1	0	-	%96,89	%95,45	%1,4	20	30	1,5	1
Yeni Tiroid	PGIRLA	1	1	-	%96,37	%86,36	%10	20	37	1,9	0,4
Yeni Tiroid	PGIRLA	1	2	-	%96,37	%90,91	%5,5	20	36	1,8	1
Yeni Tiroid	PGIRLA	1	3	-	%96,37	%86,36	%10	20	29	1,5	1
Yeni Tiroid	PGIRLA	1	4	-	%96,37	%86,36	%10	20	36	1,8	1
Yeni Tiroid	PGIRLA	1	5	-	%96,39	%95,24	%1,2	20	35	1,8	1
Yeni Tiroid	PGIRLA	1	6	-	%95,88	%80,95	%14,9	20	38	1,9	0,4
Yeni Tiroid	PGIRLA	1	7	-	%96,91	%90,48	%6,4	20	36	1,8	1
Yeni Tiroid	PGIRLA	1	8	-	%95,36	%90,48	%4,9	20	39	2	1
Yeni Tiroid	PGIRLA	1	9	-	%94,33	%95,24	-0,9%	20	31	1,6	1
Yeni Tiroid	PGIRLA	2	0	-	%96,37	%86,36	%10	20	32	1,6	1
Yeni Tiroid	PGIRLA	2	1	-	%96,37	%81,82	%14,6	20	34	1,7	0,4
Yeni Tiroid	PGIRLA	2	2	-	%96,89	%90,91	%6	20	35	1,8	1
Yeni Tiroid	PGIRLA	2	3	-	%97,41	%90,91	%6,5	20	37	1,9	1
Yeni Tiroid	PGIRLA	2	4	-	%94,82	%86,36	%8,5	20	33	1,7	1
Yeni Tiroid	PGIRLA	2	5	-	%95,88	%100	-4,1%	20	39	2	1
Yeni Tiroid	PGIRLA	2	6	-	%97,42	%100	-2,6%	20	33	1,7	0,4
Yeni Tiroid	PGIRLA	2	7	-	%94,85	%95,24	-0,4%	20	32	1,6	1
Yeni Tiroid	PGIRLA	2	8	-	%95,36	%95,24	%0,1	20	39	2	1
Yeni Tiroid	PGIRLA	2	9	-	%96,39	%100	-3,6%	20	34	1,7	1
Yeni Tiroid	PGIRLA	3	0	-	%95,85	%86,36	%9,5	20	38	1,9	1
Yeni Tiroid	PGIRLA	3	1	-	%96,37	%100	-3,6%	20	39	2	0,4
Yeni Tiroid	PGIRLA	3	2	-	%94,82	%90,91	%3,9	20	44	2,2	1
Yeni Tiroid	PGIRLA	3	3	-	%97,41	%90,91	%6,5	20	31	1,6	1
Yeni Tiroid	PGIRLA	3	4	-	%96,89	%100	-3,1%	20	37	1,9	1
Yeni Tiroid	PGIRLA	3	5	-	%95,36	%95,24	%0,1	20	34	1,7	1
Yeni Tiroid	PGIRLA	3	6	-	%95,88	%80,95	%14,9	20	35	1,8	0,4
Yeni Tiroid	PGIRLA	3	7	-	%96,39	%66,67	%29,7	20	45	2,3	1
Yeni Tiroid	PGIRLA	3	8	-	%95,88	%95,24	%0,6	20	32	1,6	1
Yeni Tiroid	PGIRLA	3	9	-	%96,39	%95,24	%1,2	20	38	1,9	1
Yeni Tiroid	PGIRLA	4	0	-	%95,85	%81,82	%14	20	40	2	1
Yeni Tiroid	PGIRLA	4	1	-	%96,37	%90,91	%5,5	20	36	1,8	0,4
Yeni Tiroid	PGIRLA	4	2	-	%95,85	%86,36	%9,5	20	36	1,8	1
Yeni Tiroid	PGIRLA	4	3	-	%95,85	%95,45	%0,4	20	38	1,9	1
Yeni Tiroid	PGIRLA	4	4	-	%96,37	%86,36	%10	20	34	1,7	1
Yeni Tiroid	PGIRLA	4	5	-	%95,88	%100	-4,1%	20	33	1,7	1
Yeni Tiroid	PGIRLA	4	6	-	%96,39	%100	-3,6%	20	38	1,9	0,4
Yeni Tiroid	PGIRLA	4	7	-	%96,39	%90,48	%5,9	20	38	1,9	1
Yeni Tiroid	PGIRLA	4	8	-	%95,88	%100	-4,1%	20	38	1,9	1
Yeni Tiroid	PGIRLA	4	9	-	%96,91	%90,48	%6,4	20	36	1,8	1
Yeni Tiroid	PGIRLA	5	0	-	%97,41	%81,82	%15,6	20	33	1,7	1
Yeni Tiroid	PGIRLA	5	1	-	%96,37	%90,91	%5,5	20	38	1,9	0,4
Yeni Tiroid	PGIRLA	5	2	-	%97,41	%77,27	%20,1	20	39	2	1
Yeni Tiroid	PGIRLA	5	3	-	%95,85	%86,36	%9,5	20	36	1,8	1
Yeni Tiroid	PGIRLA	5	4	-	%95,34	%90,91	%4,4	20	41	2,1	1
Yeni Tiroid	PGIRLA	5	5	-	%96,39	%100	-3,6%	20	31	1,6	1

Tablo EK-3.1 – tablonun devamı.

Problem	Algoritma	Pop. No.	Ç. Doğ. No.	Top. Işl. Say.	Eğ. Doğr.	Test Doğr.	Eğ.-Test Değş. Oranı	Kur. S.	Koş. S.	Oran	Süre (sn)
Yeni Tiroid	PGIRLA	5	6	-	%96,39	%85,71	%10,7	20	29	1,5	0,4
Yeni Tiroid	PGIRLA	5	7	-	%96,91	%90,48	%6,4	20	35	1,8	1
Yeni Tiroid	PGIRLA	5	8	-	%95,88	%100	-4,1%	20	38	1,9	1
Yeni Tiroid	PGIRLA	5	9	-	%96,39	%95,24	%1,2	20	37	1,9	1
Yeni Tiroid	SIA	1	0	-	%100	%95,45	%4,5	38	162	4,3	1
Yeni Tiroid	SIA	1	1	-	%100	%95,45	%4,5	39	185	4,7	1
Yeni Tiroid	SIA	1	2	-	%100	%86,36	%13,6	26	206	7,9	1
Yeni Tiroid	SIA	1	3	-	%100	%100	%0	43	195	4,5	1
Yeni Tiroid	SIA	1	4	-	%100	%90,91	%9,1	43	156	3,6	1
Yeni Tiroid	SIA	1	5	-	%100	%100	%0	50	170	3,4	1
Yeni Tiroid	SIA	1	6	-	%100	%95,24	%4,8	51	192	3,8	1
Yeni Tiroid	SIA	1	7	-	%100	%90,48	%9,5	36	183	5,1	1
Yeni Tiroid	SIA	1	8	-	%100	%100	%0	49	201	4,1	1
Yeni Tiroid	SIA	1	9	-	%100	%80,95	%19	42	198	4,7	1
Yeni Tiroid	SIA	2	0	-	%100	%90,91	%9,1	41	110	2,7	1
Yeni Tiroid	SIA	2	1	-	%100	%90,91	%9,1	43	158	3,7	1
Yeni Tiroid	SIA	2	2	-	%100	%95,45	%4,5	35	219	6,3	1
Yeni Tiroid	SIA	2	3	-	%100	%95,45	%4,5	27	151	5,6	1
Yeni Tiroid	SIA	2	4	-	%100	%90,91	%9,1	46	226	4,9	1
Yeni Tiroid	SIA	2	5	-	%100	%100	%0	38	195	5,1	1
Yeni Tiroid	SIA	2	6	-	%100	%95,24	%4,8	50	117	2,3	1
Yeni Tiroid	SIA	2	7	-	%100	%95,24	%4,8	33	180	5,5	1
Yeni Tiroid	SIA	2	8	-	%100	%100	%0	40	138	3,5	1
Yeni Tiroid	SIA	2	9	-	%100	%95,24	%4,8	30	208	6,9	1
Yeni Tiroid	SIA	3	0	-	%100	%90,91	%9,1	46	191	4,2	1
Yeni Tiroid	SIA	3	1	-	%100	%95,45	%4,5	43	209	4,9	1
Yeni Tiroid	SIA	3	2	-	%100	%95,45	%4,5	48	186	3,9	1
Yeni Tiroid	SIA	3	3	-	%100	%95,45	%4,5	41	161	3,9	1
Yeni Tiroid	SIA	3	4	-	%100	%95,45	%4,5	42	274	6,5	1
Yeni Tiroid	SIA	3	5	-	%100	%95,24	%4,8	52	228	4,4	1
Yeni Tiroid	SIA	3	6	-	%100	%95,24	%4,8	39	164	4,2	1
Yeni Tiroid	SIA	3	7	-	%100	%95,24	%4,8	48	232	4,8	1
Yeni Tiroid	SIA	3	8	-	%100	%100	%0	39	157	4	1
Yeni Tiroid	SIA	3	9	-	%100	%95,24	%4,8	38	204	5,4	1
Yeni Tiroid	SIA	4	0	-	%100	%95,45	%4,5	45	235	5,2	1
Yeni Tiroid	SIA	4	1	-	%100	%100	%0	45	227	5	1
Yeni Tiroid	SIA	4	2	-	%100	%95,45	%4,5	34	173	5,1	1
Yeni Tiroid	SIA	4	3	-	%100	%90,91	%9,1	31	184	5,9	1
Yeni Tiroid	SIA	4	4	-	%100	%95,45	%4,5	37	132	3,6	1
Yeni Tiroid	SIA	4	5	-	%100	%100	%0	37	153	4,1	1
Yeni Tiroid	SIA	4	6	-	%100	%85,71	%14,3	42	147	3,5	1
Yeni Tiroid	SIA	4	7	-	%100	%90,48	%9,5	34	228	6,7	1
Yeni Tiroid	SIA	4	8	-	%100	%100	%0	45	151	3,4	1
Yeni Tiroid	SIA	4	9	-	%100	%90,48	%9,5	41	319	7,8	1
Yeni Tiroid	SIA	5	0	-	%100	%95,45	%4,5	35	224	6,4	1
Yeni Tiroid	SIA	5	1	-	%100	%95,45	%4,5	44	182	4,1	1
Yeni Tiroid	SIA	5	2	-	%100	%90,91	%9,1	50	170	3,4	1
Yeni Tiroid	SIA	5	3	-	%100	%95,45	%4,5	47	197	4,2	1
Yeni Tiroid	SIA	5	4	-	%100	%90,91	%9,1	60	163	2,7	1
Yeni Tiroid	SIA	5	5	-	%100	%95,24	%4,8	45	191	4,2	1
Yeni Tiroid	SIA	5	6	-	%100	%95,24	%4,8	32	123	3,8	1
Yeni Tiroid	SIA	5	7	-	%100	%95,24	%4,8	69	162	2,3	1
Yeni Tiroid	SIA	5	8	-	%100	%100	%0	38	181	4,8	1
Yeni Tiroid	SIA	5	9	-	%100	%95,24	%4,8	45	197	4,4	1

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı	:	Fehim KÖYLÜ
Uyruğu	:	Türkiye (T.C.)
Doğum Tarihi ve Yeri	:	1981, Kayseri
Telefon	:	0 352 207 66 66 - 32580
Belgegeçer	:	0 352 437 57 84
E-posta	:	fehimkoylu@erciyes.edu.tr
Adres	:	Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölüm Başkanlığı 38039, Melikgazi KAYSERİ TÜRKİYE

EĞİTİM

Derece	**Kurum**	**Mez.Yılı**
Yüksek Lisans	ERÜ Fen Bil. Ens. Bilgisayar Müh. A.B.D., KAYSERİ	2006
Lisans	ERÜ Müh. Fakültesi Bilgisayar Müh., KAYSERİ	2003

İŞ DENEYİMİ

Yıl	**Kurum**	**Görev**
2006-Halen	ERÜ Mühendislik Fakültesi Bilgisayar Müh. Bölümü, KAYSERİ	Araştırma Görevlisi
2003-2006	Emek Yazılım Arge Mühendislik, KAYSERİ	Yazılım Mühendisi & Proje Koordinatörü
2004-2005	M.E.B. Kayseri Tek. ve End. Mesl. Lisesi Bilişim Teknolojileri Alanı, KAYSERİ	Vekil Teknik Öğretmen
2003-2004	Kayseri Gün Gazetesi	İmtiyaz Sahibi
1999-2001	Huzur Kargo A.Ş., KAYSERİ	Acente Yöneticisi Asistanı