

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**YAPAY SİNİR AĞI VE FOTOMETRİK YÖNTEMLER İLE
MADDE TANIMA SİSTEMİ TASARIMI**

**Hazırlayan
Ekrem Kürşad DAL**

**Danışman
Prof. Dr. Recai KILIÇ**

Yüksek Lisans Tezi

**Ocak 2017
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**YAPAY SİNİR AĞI VE FOTOMETRİK YÖNTEMLER İLE
MADDE TANIMA SİSTEMİ TASARIMI**

(Yüksek Lisans Tezi)

**Hazırlayan
Ekrem Kürşad DAL**

**Danışman
Prof. Dr. Recai KILIÇ**

**Bu çalışma; Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi
Tarafından FYL-2016-6542 kodlu proje ile desteklenmiştir.**

**Ocak 2017
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.



Ekrem Kürşad DAL

YÖNERGEYE UYGUNLUK SAYFASI

“Yapay Sinir Ağı ve Fotometrik Yöntemler ile Madde Tanıma Sistemi Tasarımı”
adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma
Yönergesi’ne uygun olarak hazırlanmıştır.


Tezi Hazırlayan

Ekrem Kürşad DAL



Danışman

Prof. Dr. Recai KILIÇ



Elektrik Elektronik Mühendisliği ABD Başkanı

Prof. Dr. Necmi TAŞPINAR

Prof. Dr. Recai KILIÇ danışmanlığında **Ekrem Kürşad DAL** tarafından hazırlanan “**Yapay Sinir Ağı ve Fotometrik Yöntemler ile Madde Tanıma Sistemi Tasarımı**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fizik Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

11 /01 /2017

JÜRİ:

Danışman :Prof. Dr. Recai KILIÇ

Üye :Doç. Dr. Ömer Galip SARAÇOĞLU

Üye :Doç. Dr. Serhan YAMAÇLI

**ONAY:**

Bu tezin kabulü Enstitü Yönetim Kurulunun 25/01/2017 tarih ve 2017/04-36 sayılı kararı ile onaylanmıştır.



Prof. Dr. Mehmet AKKURT
Enstitü Müdürü

TEŞEKKÜR

“Yapay Sinir Ağı Ve Fotometrik Yöntemler İle Madde Tanıma Sistemi Tasarımı” konulu tez çalışmamda emeğini esirgemeyen saygıdeğer hocam Prof. Dr. Recai KILIÇ’a, değerli arkadaşım Arş. Gör. Oğuzhan AYYILDIZ’a, tezin her aşamasında desteklerinden dolayı canım aileme ve saygıdeğer arkadaşlarıma sevgi ve saygılarımı sunarım.

Erciyes Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi’ne FYL-2016-6542 kodlu proje desteğinden dolayı teşekkürlerimi sunarım.

YAPAY SİNİR AĞI VE FOTOMETRİK YÖNTEMLER İLE MADDE TANIMA SİSTEMİ TASARIMI

Ekrem Kürşad DAL

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Ocak 2017
Danışman: Prof. Dr. Recai KILIÇ**

ÖZET

Biyolojik terör, kimyasal kirlilik, uygunsuz gıda maddeleri, hastalık yapıcı mikroorganizmalar gibi konularda madde ayırt etme ve tanıma işlemleri önem arz etmekte olup, bu işlemlerin yerinde hızlı ve yüksek doğrulukta yapılması gerekmektedir. Fotometrik metotlar, madde ayırımı için en çok başvurulan metotlar arasında yer almakta olup, maddenin optik özelliklerini kullanarak madde ayırımını gerçekleştirmektedir.

Bu tez çalışmasında; YSA destekli otonom karar mekanizmalı, 365nm-950nm dalgaboyu aralığında, 22 LED’li ışık kaynağına ve geniş spektral aralık ile kızılötesi spektral aralığında iki fotodiyotlu ışık dijital dönüştürücüsüne sahip bir fotometrik tabanlı madde tanıma sistemi tasarlanmış ve gerçekleştirilmiştir.

Tasarlanan sistemin madde tanıma performansının tespit edilmesi amacıyla; süt, su ve etil alkol sıvıları üzerinde deneyler gerçekleştirilmiştir. Süt ile ilgili deneylerde; sütün markası ve bekleme süresine göre sınıflandırması ele alınmıştır. Su ile ilgili deneylerde ise suyun kaynağına göre sınıflandırma işlemleri denenmiştir. Su ile birlikte etil alkol incelenmiş ve bu deneyler sonucunda tasarlanan sistemin madde ayırımı ve tanıma işlemlerinde başarılı bir performans gösterdiği kanıtlanmıştır.

Anahtar Kelimeler: Fotometrik sistemler, madde tanıma ve sınıflandırma, absorbans ve reflektans ölçümü, YSA, LED

DESIGN OF SUBSTANCE IDENTIFICATION SYSTEM WITH ARTIFICIAL NEURAL NETWORK AND PHOTOMETRIC METHODS

Ekrem Kursad DAL

Erciyes University, Graduate School of Natural and Applied Sciences

M.Sc. Thesis, January 2017

Supervisor: Prof. Dr. Recai KILIC

ABSTRACT

Substance identification and recognition about biologic terror, chemical pollution, inappropriate foods, disease-causing microorganisms etc. is important, and this process must be in-situ, fast and highly accurate. Photo metric methods, which are one of the most applied methods, utilize optic properties to identify the substance.

In this thesis work, we designed a photometric based substance identification system which is supported with Artificial Neural Network (ANN) with 22 LEDs, whose spectral range is 350nm to 950nm, and has the light to digital converter (LDC) sensor consists of two photodiodes, the one is for wide bandwidth the second one is for infrared spectral range.

To test performance of designed system we conducted the experiments on milk, water and ethyl alcohol. In the first experiment, we tried to classify milk based on brand and waiting time. In the second experiment, we endeavored to label water according to spring. Lastly, we analyzed water versus ethyl alcohol to test limitations. We proved that our system can accurately classify substance based on optical properties.

Keywords: photometric systems; substance identification and classifying; absorbance and reflectance measurement, ANN, LED

İÇİNDEKİLER

YAPAY SİNİR AĞI VE FOTOMETRİK YÖNTEMLER İLE MADDE TANIMA SİSTEMİ TASARIMI

BİLİMSEL ETİĞE UYGUNLUK	i
YÖNERGEYE UYGUNLUK SAYFASI	ii
KABUL VE ONAY	iii
TEŞEKKÜR	iv
ÖZET	v
ABSTRACT	vi
İÇİNDEKİLER.....	vii
KISALTMALAR VE SİMGELER	x
TABLolar LİSTESİ	xi
ŞEKİLLER LİSTESİ.....	xii
 GİRİŞ.....	 1

1. BÖLÜM

GENEL BİLGİLER

1.1. Literatür Taraması.....	3
1.2. Genel Fotometrik Sistem Bileşenleri	9
1.3. Işık Kaynağı Olarak LED Kullanılan Fotometrik Ölçüm Sistemleri.....	11
1.4. Yapay Sinir Ağı.....	16
1.4.1. Biyolojik Sinir Ağ Yapısı.....	16
1.4.2. Yapay Sinir Ağı'nın Avantajları	18
1.4.3. Yapay Sinir Ağı'nın Dezavantajları.....	20
1.4.4. Yapılarına Göre Yapay Sinir Ağı.....	21
1.4.5. Yapay Sinir Ağı Öğrenme Metotları.....	21
1.4.6. Yapay Sinir Ağı ile İlgili Uygulama Modülleri	21

2. BÖLÜM

YAPAY SİNİR AĞI DESTEKLİ LED'Lİ FOTOMETRİK SİSTEMİN DONANIMSAL GERÇEKLEŞTİRİMİ

2.1. Sistemin Bileşenleri	25
2.1.1. Işık Kaynağı	27
2.1.2. Sensörler	32
2.1.3. Kontrol Ünitesi.....	35
2.1.4. Motor	36
2.1.5. Bilgisayar Arayüzü	37
2.2. Verinin Alınması ve İşlenmesi.....	39

3. BÖLÜM

LED'Lİ FOTOMETRİK ÖLÇÜM SİSTEMİ DENEYLERİ

3.1. Süt Üzerinde Yapılan Deneyler	45
3.1.1. Sütün Markasına Göre Sınıflandırılması	46
3.1.2. Markaya Göre Süt Verileri Üzerinde Ranker Metodu ile Özellik Seçimi.....	48
3.1.3. Markaya Göre Süt Verisi Üzerinde Test Verisi Kullanımı	50
3.1.4. Sütün Bekleme Süresine Göre Sınıflandırılması	53
3.1.5. Sütün Bekleme Süresi Verileri Üzerinde Ranker Metodu ile Özellik Seçimi	53
3.1.6. Bekleme Süresine Göre Süt Verisi Üzerinde Test Verisi Kullanımı.....	55
3.2. Su ve Etil Alkol Üzerinde Yapılan Deneyler	57
3.2.1. Kaynağına Göre Su Üzerinde Yapılan Deneyler	57
3.2.2. Su Verileri Üzerinde Ranker Metodu ile Özellik Seçimi	58
3.2.3. Su Verileri Üzerinde Test Verisi Kullanımı	60
3.2.4. Su Verileri İle Birlikte Etil Alkolün Eğitilip Sınanması.....	61
3.2.5. Su ve Alkol Verileri Üzerinde Ranker Metodu ile Özellik Seçimi	63
3.2.6. Yapay Sinir Ağında Su ve Alkol Üzerinde Test İşlemleri.....	64

4. BÖLÜM**TARTIŞMA-SONUÇ ve ÖNERİLER**

KAYNAKLAR.....	69
ÖZGEÇMİŞ	81

KISALTMALAR VE SİMGELER

<u>Sembol</u>	<u>Anlamı</u>	<u>Birimi</u>
Φ_e^i	Işık Akısı	(Cd)
DNA	Deoksiribo Nükleik Asit	
FPGA	Field Programmable Gate Array (Alanda Programlanabilir Kapı Dizileri)	
LED	Light Emitting Diode (Işık Yayan Diyot)	
NMR	Nükleer Manyetik Rezonans	
PEDD	Paired Emitter-Detector Diode (Eşleştirilmiş Yayan-Algılayan Diyot)	
SoC	System on Chip (Entegre Üzerindeki Sistem)	
TNB	Trinitrobenzen	
TNT	Trinitrotoluen	
UV	Ultraviyole	
YSA	Yapay sinir ağı	

TABLOLAR LİSTESİ

Tablo 1.1. Maddenin Ayırt Edici Özellikleri	4
Tablo 1.2. Biyolojik Sinir Sisteminin Yapay Sinir Ağı Karşılığı	17
Tablo 2.1. Kullanılan LED’lerin Tepe Dalgaboyları	29
Tablo 3.1. Yapay Sinir Ağı Eğitim Parametreleri.....	47
Tablo 3.2. Markasına Göre Süt Verisinin InfoGain Değerlendiricisinin Ranker Metodu ile En İyi 18 Parametresi	49
Tablo 3.3. Markasına Göre Süt Verisinin Ranker Metodu ile Seçilen En İyi 18 Özelliklerinin Sistem Başarısı Üzerine Etkileri.....	49
Tablo 3.4. Bekleme Süresine Göre Süt Verisinin InfoGain Değerlendiricisinin Ranker Metodu ile En İyi 18 Özelliği	54
Tablo 3.5. Bekleme Süresine Göre Süt Verisinin Ranker Metodu ile Seçilen En İyi 18 Özelliğinin Sistem Başarısı Üzerine Etkileri.....	54
Tablo 3.6. Seçilen 12 Özellik İçin Bekleme Süresine Göre Süt Verisi Üzerinde Hata Tablosu.....	56
Tablo 3.7. Seçilen 176 Özellik İçin Bekleme Süresine Göre Süt Verisi Üzerinde Test Verisi Hata Tablosu	57
Tablo 3.8. Kaynağına Göre Su Verisinin InfoGain Değerlendiricisinin Ranker Metodu ile En İyi 18 Özelliği	59
Tablo 3.9. Kaynağına Göre Su Verisinin Ranker Metodu ile Seçilen En İyi 18 Özelliklerinin Sistem Başarısı Üzerine Etkileri.....	59
Tablo 3.10. 176 Özellik İçin Kaynağına Göre Su Verisi Üzerinde Test Verisi Hata Tablosu	60
Tablo 3.11. Su ve Etil Alkol Verilerinin Ranker Metodu ile Seçilen En İyi 18 Özelliği	63
Tablo 3.12. Su ve Etil Alkol Verilerine Göre Ranker Metodu ile Seçilen En İyi 18 Özelliklerinin Sistem Başarısı Üzerine Etkileri.....	64
Tablo 3.13. 176 Özellik İçin Su ve Etil Alkol Verisi Üzerinde Test Verisi Hata Tablosu	65

ŞEKİLLER LİSTESİ

Şekil 1.1. Fotometrik Sistem Blok Diyagramı.....	9
Şekil 1.2. LED-Fototransistör Çiftinden Oluşan Transduser Hücresinin Kesit Görüntüsü	11
Şekil 1.3. LED Fotodiyot Çiftinden Oluşan Transduser Hücresinin Kesit Görünüşü. .	12
Şekil 1.4. Akış Tipi Sistemde LED-LDR Çifti Kullanımı.....	12
Şekil 1.5. Çift Işınlı LED Optik Sensör Yapısı.....	13
Şekil 1.6. Çoklu LED’li fotometre devre şeması.....	14
Şekil 1.7. Ortak Anot RGB LED’in İç Yapısı	14
Şekil 1.8. Toplamsal Renk Sistemi.	15
Şekil 1.9. (a) Kaynaştırılmış LED’ler (b) Optik probun kesit görüntüsü	15
Şekil 1.10. Biyolojik sinir hücresi ve bağlantıları	17
Şekil 1.11. Yapay Sinir Ağının Matematiksel Modeli.....	18
Şekil 1.12. MATLAB YSA Aracı (nnstart).	22
Şekil 1.13. WEKA Yazılımının Arayüzü	23
Şekil 2.1. Sistemin blok diyagramı	25
Şekil 2.2. Sistemin Üç Boyutlu Görüntüsü.....	26
Şekil 2.3. Diskin Ön ve Arka Görünümü.....	26
Şekil 2.4. Sistemin Ön ve Arka Görünümü	27
Şekil 2.5. Soğuk Beyaz ve Sıcak Beyaz LED’in Spektrumu.....	27
Şekil 2.6. Pembe LED’in Spektrumu.....	28
Şekil 2.7. PCF8574 Blok Diyagramı	31
Şekil 2.8. PCF8574 için her bir Giriş/Çıkış için basitleştirilmiş iç devre şeması.....	31
Şekil 2.9. PCF8574 Adres Yapısı	31
Şekil 2.10. PCF8574A Adres Yapısı	32
Şekil 2.11. PCF8574 Zamanlama Diyagramı	32
Şekil 2.12. TSL2561 Sensörünün Spektral Duyarlılığı.	33
Şekil 2.13. TSL2561’in Blok Diyagramı.....	33

Şekil 2.14. TSL2561 sensörünün açılmal yer değıştirmesi grafiđi	34
Şekil 2.15. Tasarlanan Sistemdeki I ² C Bađlantısı	35
Şekil 2.16. Arduino Nano kartının görüntüsü.....	36
Şekil 2.17. Dynamixel AX-12A pin yapısı.....	36
Şekil 2.18. MATLAB Aygıt Kontrol Araç Kutusu Arayüzü.....	40
Şekil 3.1. WEKA Üzerinde Verilerin Dađılımının Görülmesi.....	46
Şekil 3.2. Markasına Göre Süt Verisinin Karışıklık Matrisi (Çapraz Doğrulama).....	47
Şekil 3.3. Markasına Göre Süt Verisinin Karışıklık Matrisi (Test Verisi ile Analiz)...	50
Şekil 3.4. Markasına Göre Süt Verisinin Karışıklık Matrisi (176 Özellik İçin Test)...	51
Şekil 3.5. Markasına Göre Süt Verisinin Karışıklık Matrisi (Seçilen 12 Özellik İçin Test).....	52
Şekil 3.6. Bekleme Süresine Göre Sütün Karışıklık Matrisi (Çapraz Doğrulama)	53
Şekil 3.7. Bekleme Süresine Göre Sütün Karışıklık Matrisi (Seçilen 12 Özellik İçin Test).....	55
Şekil 3.8. Bekleme Süresine Göre Sütün Karışıklık Matrisi (176 Özellik İçin Test)...	56
Şekil 3.9. Kaynađına Göre Su Karışıklık Matrisi (Çapraz Doğrulama)	58
Şekil 3.10. Kaynađına Göre Su Karışıklık Matrisi (176 Özellik İçin Test).....	61
Şekil 3.11. Etil Alkol Molekülü.....	62
Şekil 3.12. Su Molekülü.	62
Şekil 3.13. Su ve Etil Alkol Karışıklık Matrisi (Çapraz Doğrulama).....	62
Şekil 3.14. Su ve Etil Alkol Karışıklık Matrisi (176 Özellik İçin Test).	66

GİRİŞ

Maddeleri ayırt edebilmek insanlığın en büyük problemlerinden birisi olmuştur. Maddelerin ayırt edici özellikleri konusunda bugüne kadar sayısız çalışma yürütülmüş ve farklı birçok metot geliştirilmiştir. Günümüzde madde tanımaya yönelik olarak geliştirilen sistemler pahalı ve kullanımı zordur. Bu konuda kullanıcı dostu, hızlı sonuç veren, taşınabilir ve ucuz sistemlerin tasarım ve gerçekleştirim çalışmaları ilgi çekmektedir.

Yapay Sinir Ağı (YSA), insan beynindeki milyonlarca nöronun bilgiyi paralel işlemesinden esinlenerek geliştirilmiş, hesaplamalı bir metottur. Dijital sistemlerin öğrenmesine ve öğrendiklerine göre karar vermesinde önemli bir noktada olan yapay sinir ağı ile insansız sistemler oluşturulabilmektedir. İnsansız sistemlerin kullanılması ile insanlara bağlı olan hatanın bertaraf edilmesi amaçlanmıştır.

Bu tez çalışmasında; madde tanımaya yönelik LED tabanlı ucuz, hızlı sonuç veren, taşınabilir güvenilir bir fotometrik sistem tasarımı amaçlanmıştır. Tasarlanan sistemde 22 farklı LED ile 365nm-950nm arasındaki dalga boyu aralığını kapsayacak ışık kaynağı oluşturulmuştur. TSL2561 (AMS AG) ışık dijital dönüştürücü (Light to Digital Converter) sensörü ile yaklaşık olarak 250nm'den 1100nm'ye kadar spektral aralıkta algılama düzeneği kurgulanmıştır. Böylece LED'lerin oluşturmuş olduğu spektral bölgenin verimli şekilde kullanılması amaçlanmıştır. Sensörden kızılötesi, görülür, tam (full band) bölgeden ve lüks biriminden olmak üzere dört farklı ölçüm verisi ve bunların her biri için parametrik absorptans ve reflektans verileri elde edilmiştir. Her bir LED için 8 ölçüm verisi olmak üzere; toplamda 22 LED için 176 özellik, madde tanıma işleminde kullanılmıştır. Alınan ölçümler, RS232 haberleşme protokolü üzerinden MATLAB (MathWorks) programına aktarılmış ve ARFF dosyası haline dönüştürülmüştür. YSA işlem özelliğine sahip bir yazılım olan WEKA programı kullanılarak ölçüm verilerinden otonom bir formatta madde tanıma süreci ile ilgili çıkarımlarda bulunulmuştur.

Tasarlanan sistemin performansını test etmek için 4 farklı sınıflandırma deneyleri yapılmıştır. Birinci deneyde; sütun markasına göre, ikinci deneyde sütun bekleme gününe göre, üçüncü deneyde suyun kaynağına göre ve son olarak da su ve etil alkolün sınıflandırılma problemleri ele alınmıştır.

Bölüm 1’de literatür özeti verildikten sonra, fotometrik sistemler ve yapay sinir ağı ile ilgili temel kavramlar üzerinde durulmuştur. İkinci bölümde tasarlanan sistemin donanımsal yapısı, teknik özellikleri ve verilerin elde edilmesi açıklanmıştır. Bölüm 3’te deneysel verilerin değerlendirilmesi süreci verildikten sonra son bölümde madde tanıma ve sınıflandırmayla ilgili yapılan deneylerin yorumlanması yapılmış tasarlanan sistemin tasarım özellikleri ve geliştirilebilirlik konuları tartışılmıştır.

1. BÖLÜM

GENEL BİLGİLER

1.1. Literatür Taraması

Maddenin optik özellikleri maddenin cinsi, yoğunluğu, rengi gibi konularda bilgi vermektedir. Madde ayırım yöntemleri incelendiğinde; nicel ve nitel metotların olduğu görülmektedir. Bazı maddeler koku, tat, renk ve yoğunluğa göre ayırt edilebilirken, bazı maddelerin ise hassas ölçüm cihazları ve düzenekleri olmadan ayırt edilmesi mümkün olamamaktadır. Acı ve tatlı maddeler tatma duyusu ile ayırt edilebilirken, asit ve bazları ayırmak için turnusol kağıdı kullanılması [1-5], glikoz ayırımı için Benedict çözeltisi kullanımı [6,7], nişasta ayırımı için iyot çözeltisi kullanımı [8-17] gibi kimyasal metotlar da madde ayırt edebilmede gerekli olabilmektedir. Kimyasal metotlar, aranan maddenin var olması durumunda numunede değişiklik oluşumunun fark edilmesini sağlayan metotlardır. Örneğin; boyar madde kullanılması en sık kullanılan kimyasal metotlardan birisidir. Bu metotta tespit edilecek madde ile boyar maddenin reaksiyona girerek renk değişimi oluşturulması esastır. Kabarcık çıkışının olması, maddenin ısınması (ekzotermik reaksiyon) ya da soğuması (endotermik reaksiyon), maddenin numunenin altına çökmesi gibi farklı kimyasal metotlar da mevcuttur.

Fiziksel metotlar ise, maddenin yapısını değiştirmeden madde tanımaya yönelik olan çalışmaları içermektedir. Maddenin fiziksel halini (katı-sıvı-gaz) değiştirerek, maddeyi süzerek, maddeyi yüzdürerek ya da farklı fiziksel metotlar kullanılarak madde tanımlanabilmektedir. Örneğin etil alkol, suya göre daha düşük sıcaklıkta buharlaşmakta olup, kaynama sıcaklığı kontrol edilerek etil alkol ile su ayırt edilebilmektedir. Maddenin fiziksel haline göre ayırt edici özellikler Tablo 1.1’de verilmiştir. Bu tabloya göre ayırt edicilik için seçilen yöntem maddenin fiziksel haline göre farklılaşabilmektedir.

Bazı maddelerin ölçülebilmesi ve ya tespit edilebilmesi için cihaz kullanımı ile birlikte ayraç madde kullanımı gerekebilmektedir. Örneğin; içme suyundaki minerallerin, tespiti ve miktarının ölçümünde ayraç madde kullanımı ile birlikte cihaz kullanımı gerekebilmektedir. Maddeleri tanımlayan ve ölçen cihazlar maddenin optik, manyetik, iletkenlik, alev rengi, pH'sı gibi farklı özelliklerine göre çıkarım yapmaktadırlar.

Tablo 1.1. Maddenin Ayırt Edici Özellikleri

Ayırt Edici Özellikler	Katı	Sıvı	Gaz
Öz Kütle	+	+	+
Öz Hacim	+	+	+
Öz Isı	+	+	+
Öz Ağırlık	+	+	+
Çözünürlük	+	+	+
Tutuşma Sıcaklığı	+	+	+
Renk	+	+	+
Erime Sıcaklığı	+	-	-
Esneklik	+	-	-
Sertlik	+	-	-
Kaynama Sıcaklığı	-	+	-
Donma Sıcaklığı	-	+	-
Buhar Basıncı	-	-	+
Yoğunlaşma Sıcaklığı	-	-	+
İletkenlik	+	+	+
Genleşme	+	+	-
Tat	+	+	-
Koku	+	+	+

Bazı maddelerin ölçülebilmesi ve ya tespit edilebilmesi için cihaz kullanımı ile birlikte ayraç madde kullanımı gerekebilmektedir. Örneğin; içme suyundaki minerallerin, tespiti ve miktarının ölçümünde ayraç madde kullanımı ile birlikte cihaz kullanımı gerekebilmektedir. Maddeleri tanımlayan ve ölçen cihazlar maddenin optik, manyetik, iletkenlik, alev rengi, pH'sı gibi farklı özelliklerine göre çıkarım yapmaktadırlar.

Optik olarak çalışan cihazların en tipik örneği spektrofotometrelerdir. Spektrofotometreler, maddenin ışığa bağlı özelliklerini kullanarak maddeleri ayırt etmektedir. Spektrofotometreler kullandıkları yöntemlere, spektral ölçüm aralığına göre adlandırılmaktadırlar. Örneğin; raman spektrofotometreleri Raman saçılımına bağlı

olarak ölçüm yaparken [18], floresans spektrofotometreleri maddeden yayılan ışığa göre [19] göre, UV/Vis spektrofotometreleri ultraviyole ve görölür bölgede, genellikle absorbans miktarı ölçümüne göre maddenin bulunduğu spektrum bölgesini ve yoğunluğunu tanımlar. Literatürde gıda [20-24], çevre [25-30], sağlık [31-35], kimya [36-40] gibi farklı branşlarda spektrofotometre cihazları kullanılan çok sayıda çalışma bulunmaktadır.

Manyetik olarak çalışan cihazlara NMR (Nükleer Manyetik Rezonans) spektroskopisi cihazları örnek verilebilir. NMR Spektroskopisi, atom çekirdeğinin belirli manyetik özelliklerini kullanan ve içerisindeki atomların ya da moleküllerin, fiziksel ve kimyasal özelliklerini belirleyen bir tekniğe sahiptir. NMR spektroskopisi nükleer manyetik rezonans olgusuna dayanmaktadır ve içerisindeki atomun ya da molekülün yapısı, dinamiği, reaksiyon durumu ve molekülün kimyasal çevresi hakkında detaylandırılmış bilgi sağlamaktadır. Molekül içerisinde ki bir atomun atom içi manyetik alanı, rezonans frekansını değiştirdiği için molekülün elektronik yapısının detaylarına erişimi sağlamaktadır [41]. Bu cihazlar ebatlarının büyük olması sebebiyle, yerinde analiz yapabilme özelliğine sahip değildirler. NMR cihazı kullanılarak yapılan çalışmalar kimya [42-45] alanında yoğunlaşmış olmakla birlikte, biyokimya alanında protein [46, 47] ya da gıda alanında nişasta [48] gibi maddeler üzerinde yapılmış çalışmalara da rastlanılmaktadır.

İletkenlik ölçerler (conductivity meter) maddeleri iyi iletken, kötü iletken olarak ya da yalıtkan olarak ayırabildiği gibi çözeltilerin ayrılmasında da kullanılabilir. Örneğin; tuz-su çözeltilerinin iletkenliği saf suya göre çok daha yüksektir ya da şekerli su çözeltisi iletkenliği çok düşük iken baz-su çözeltisinin iletkenliği daha yüksektir. Bu şekilde çözeltileri de iletkenliklerine göre ayırabilmek, herhangi bir kimyasal reaksiyon gerçekleştiğinde oluşabilecek yeni maddenin iletkenlik değerlerine bakılarak reaksiyonun sonucunda yeni molekülün oluştuğunu anlayabilmek mümkündür. Metaller için birim kesit alanında ve uzunluğunda ölçümler alındığında ise metaller için ayırt edici özellik olarak karşılaşılmaktadır. Metallerdeki bu karşılaştırma daha çok kablo üretimi yapmakta olan firmalarca yapılarak üretilen kablonun öz iletkenlik değerleri kablo üzerinde belirtilmektedir.

Alev rengi üzerinden madde tayini yapabilmek için alev spektrofotometreleri kullanılır. Klasik spektrofotometrelerden farklı olarak bir ışık kaynağı yoktur ve ölçülecek olan maddenin ışıması üzerinden madde tayini yapılır. Oda sıcaklığındaki bir maddenin atomlarının çoğu temel enerji seviyesindedir. Temel enerji seviyesindeki atomlar alev ile uyarılarak uyarılmış enerji seviyesine çıkarılırlar. Uyarılmış enerji seviyesinde atomlar karasız halde olduğu için uyarılmış atomun ömrü kısadır ve fazla enerjisini uzaklaştırarak kararlı olduğu temel enerji seviyesine dönmek ister. Atomlar temel enerji seviyesine dönerken fazla enerjisinin tümünü veya bir kısmını ışık yayarak uzaklaştırabilir ve böylece sistemden bir ışık yayılımı meydana gelir. Yayılan ışığın şiddetine ve dalga boyuna göre madde tayini yapılır.

pH ölçümü, pH metreler ya da boyar ayraçlar (fenol kırmızısı, turnusol kağıdı) vasıtası ile gerçekleştirilir. pH ölçüm yöntemi her ne kadar temelde asit ve bazların ayrılmasında kullanılsa da günümüzde birçok noktada farklı maddelerin ayrımında kullanılmaktadır. Örneğin sütlerin bozulup bozulmadığının anlaşılmasında pH ölçümü sıklıkla kullanılan bir yöntemdir. Bunun yanı sıra kozmetik ürünlerin cilde temasının uygun olup olmamasında kullanılan testlerden birisidir.

Maddeleri ayırmak için kullanılan cihazlar ve yöntemler tüm madde ayırım işlemlerinde kullanılamayıp, özelliklerine göre belirli maddeler için uygulanabilmektedir. Örneğin iletkenlik ölçüm yöntemi aynı kesite ve uzunluğa sahip metalleri tanımada kullanılabilirken, yalıtkan maddeleri tanımada ve ölçmede kullanılamamaktadır.

Literatürde sağlık ve gıda alanlarında madde ayrımı, tanımlanması ya da sınıflandırılması konularında; hastalık yapan kimyasalların [49,50], toksinlerin [51], zehirlerin tespit edilmesi [52], gıda alanında gıda kalitesinin kontrol edilmesi [53] ve bozulmuş gıda maddelerinin tespit edilmesi [54] çalışmaları rapor edilmiştir.

Biyoloji alanında nükleik asitlerin etiketlenmesinde [57], bakteri [58] ve mantar [59] çalışmalarında fotometrik madde ayırım yöntemleri kullanılmaktadır. Sağlık alanında madde ayrımı yöntemleri kullanan çalışmalarının bir kısmı da biyoloji alanı ile ortaklık göstermektedir.

Çevre alanında su kaynaklarının araştırılmasında [55] ya da kirliliğe sebep olan maddelerin ve yoğunluğunun tespitinde [56], nitrat/nitrit, amonyak, fosfor, kation ve anyonların tespitinde fotometrik madde ayırım yöntemleri kullanılmaktadır. Worsfold ve arkadaşları çeşitli analitler ile özellikle fosfat [60-63] ve nitrat/nitrit ve amonyak'ı [64-67] bulunduğu yerde gözlemlemek için LED temelli kimyasal sensörleri başarılı bir şekilde kullanmışlardır. O'Toole ve arkadaşları eşleştirilmiş ışık yayıcı-tespit edici diyot (PEDD-c) yardımı ile fosfat tespitinde bulunmuştur [68].

Gıda alanında özellikle gıdaların içerisinde üreyen zararlı mikroorganizmalar, gıdaların içerikleri zararlı ve yararlı içerikler, maya kültürü üzerinde yapılan çalışmalar gibi farklı konu başlıklarında fotometrik ölçümler yapılan çalışmalara rastlanılmıştır. Bazı çalışmaların biyoloji alanı ile ortak konular olduğu yapılan araştırmalar neticesinde görülmüştür.

Kimya alanının birçok konusunu doğrudan kapsamakta olup, kimyasal reaksiyonların izlenmesinde[38], metal iyonları üzerindeki çalışmalarda[39-40], organik ve inorganik kimyasal madde tespitlerinde, biyokimyasal madde incelemelerinde fotometrik yöntemlerin kullanıldığı görülmüştür.

Güvenlik alanında terör faaliyetlerinin önlenmesinde patlayıcıların, patlayıcı ham maddelerinin tespiti oldukça önemlidir. Ayrıca bazı maddelerin (örneğin tıbbi ya da zirai ilaçların) sağlık üzerindeki etkilerinin izlenmesi gereklidir. Bu tespitin olabildiğince hızlı ve yerinde yapılması olası problemlerin çözümünde katkı sağlayacaktır. Lu ve arkadaşları deniz suyunda bulunan TNT (Trinitrotoluen), TNB(trinitrobenzen) ve tetril (trinitrofenil-N-metilnitramin) tespitini yeşil (505nm) LED'li bir sistem kullanarak tespit etmişlerdir [69]. Bunların yanında DNA'yı analiz edebilecek, iki LED'li taşınabilir cihaz ile 2001 yılındaki biyolojik saldırıda Washington DC'de posta ofislerinde şarbon tespit edilmiştir [70].

Ölçümlerin analizi spektrofotometre gibi pahalı makineler ve karmaşık süreçler gerektirmektedir. Karmaşık süreçler ve düşük taşınabilirlikteki cihazlar ise hata miktarını artırmaktadır. Alınan numunenin yerinde incelenmesini gerektiren birçok durumda numunenin bozulmadan taşınmasını zorlaştırmakta ve hatalı değerlendirmesine sebep olabilmektedir. Bu tip cihazlar çoğunlukla sonuçların

değerlendirilmesinde teknik bilgiye sahip insan emeği gerektirmektedir. Bilinmeyen bir maddenin ölçülmesi için değerlendirme yapacak kişinin eğitilmesini gerektirebilmekte bu da değerlendirme sürecinin uzamasına, hatalı değerlendirmelerin olabilmesine yol açabilmektedir.

Günümüzde akıllı sistemler geliştirilerek çalışan insanlar yerine kullanılmaya başlamıştır. Dil tercümesi yapma, fotoğrafta yüzü algılama ve yüz sahibini tespit etme, kişilerin alışkanlıkları, hobileri üzerine tahminde bulunma gibi konular üzerinde etkin bir şekilde çalıştığı gözlemlenmiştir. Benzer algoritmalar donanımların içerisinde kullanılarak örneğin otomotiv sektöründe yol takibi, kaza önleme sistemleri, yol uyarılarını gözlemleme, adaptif hız ve mesafe kontrolü, yorgunluk kontrolü, otomatik pilot, akıllı fren ve gaz sistemleri, sürüş alışkanlıklarının tespiti konularında akıllı sistemler gerçekleştirilmiş ve hâlihazırda kullanılmaktadır. Elektronik sistemlerin tepki süreleri, algılama kabiliyetleri insanlarınkinden daha hızlı olması sebebiyle, bu sistemler ile daha konforlu ve daha güvenli seyahat mümkün hale getirilmiştir [71,72].


Yapay sinir ağı; öğrenebilen, kendini geliştirebilen, parametrelere uyum sağlayabilen kullanımı kolay ve esnek zeki algoritmalar arasında yer almaktadır. Esnek yapısı sayesinde entegre devre olarak yada yazılım kodu olarak geliştirilebilmektedir. Örneğin; CogniMem firmasının üretmiş olduğu CM1K entegresi, üzerinde 1024 yapay sinir hücresi bulunduran entegre devre elemanıdır. Bunun dışında alan programlanabilir kapı dizileri ya da mikrodenetleyiciler üzerinde programlamayı kolaylaştıran kütüphanelerin ve paketlerin oluşturulduğu gözlemlenmiştir. Bu sayede yapay sinir ağı algoritması, elektroniğe uyarlanabilir algoritmalar arasında aktif olarak kullanılabilecek duruma gelmiştir. Drone olarak isimlendirilen insansız hava araçlarında aktif olarak dengeyi ayarlayabilmek, dış ortam parametrelerini sisteme dahil ederek stabiliteyi sağlamak amacıyla kullanılmaktadır.

Bu tez çalışmasında geliştirilen sistemde; yenilikçi fotometrik ölçüm yöntemleri, yapay sinir ağı ile birleştirilerek karmaşık süreçlerin önüne geçilmesi, taşınabilir, stabil ve ucuz bir madde tanıma sisteminin gerçekleştirilmesi amaçlanmıştır. YSA sayesinde maddenin yorumlanması için teknik bilgi gerekmemekte, daha önce tanıtılmış olan madde YSA tarafından sınıflandırılmaktadır. 176 girişin birçok algoritma ve numerik metodun işleyebilmesi için oldukça fazla olup, YSA'da probleme neden olmaması da

YSA'nın sahip olduğu avantajlarından birisidir. Bunun yanı sıra ölçülecek maddeyi öğrenmesi, ağı bu maddeye göre şekillendirmesi sayesinde daha önce üzerinde çalışmaların olmadığı bir numunenin tanımlanması konusunda YSA hızlı cevap verebilmektedir.

1.2. Genel Fotometrik Sistem Bileşenleri

Fotometrik sistemler; ışık kaynağı, optik düzenek ya da optik yol, ölçülecek madde, dedektör ve ölçümlerin değerlendirildiği kontrol biriminden oluşmaktadır. Genel yapıya ait blok diyagram Şekil 1.1.'de verilmiştir.



Şekil 1.1. Fotometrik Sistem Blok Diyagramı

Işık kaynağı olarak LAZER'ler, LED'ler, döteryum lambalar, ark lambaları, flüoresans lambalar, halojen lambalar, x-ışını tüpleri gibi farklı ışık kaynakları tekli ya da çoklu olarak kullanılabilir. Kullanılan ışık kaynağı ölçülecek olan madde açısından oldukça büyük öneme sahiptir. Kullanılan ışığın dalga boyu sistemde ölçülebilecek maddelerin çeşitliliğini etkilemektedir. Kaynak olarak kullanılan ışığın dalgaboyu küçüldükçe daha küçük bileşenlere sahip maddeleri ölçebilmektedir.

Optik düzenek ise monokromatörler gibi farklı yapıda optik filtreler, optik fiberler, mercekler, aynalar ve dağıtıcı lensler gibi yapılardan oluşmaktadır. Monokromatörler ışığın yan dalgaboylarını engelleyerek tek renkli ışık yapmak, optik filtreler ışığın istenilmeyen bantlarını durdurup istenilen bantları geçmesini sağlamak, optik fiberler ışığı bir kaynaktan hedefe taşımak, mercekler ışığı odaklamak ve bir yerde toplamak ya da dağıtmak, aynalar ışığı yansıtarak bir hedefe yönlendirmek, dağıtıcı lensler ışığı tayflarına ayırmak amacıyla kullanılmaktadır.

Dedektörler, üzerine düşen ışığın seviyesinin algılanmasında kullanılan devre elemanlarından oluşan düzeneklerdir. Bu düzeneklerde kullanılan elemanlar; fotodiyot, fototransistör, fotodirenç gibi ışığı algılama amaçlı sensörler olabilirken, ışık üreten kaynaklardan olan LED ya da ışık enerjisinden elektrik üreten güneş pili de olabilmektedir. Bazı cihazlarda ise bu elemanlar bir dizi ya da matris haline getirilerek kullanılabilir.

Kuvvetlendiriciler, gelen sinyalin genlik ya da akım değerlerini istenilen oranda kuvvetlendiren elemanlardır. Dedektörden alınan sinyaller çok zayıf olabilmekte bu da maddenin algılanmasında problem teşkil edebilmektedir. Yapısına göre Op-Amp'lı ya da transistörlü kuvvetlendiriciler kullanılabilir.

Ana kontrol ünitesi; sistemin çalışmasını düzenleyen, denetleyen, dedektörden gelen verileri anlamlı veriler haline getiren, bilgisayar ile sistemin bağlantısını sağlayan ve ölçüm sonuçlarının gösterilmesini sağlayan devre elemanları bulundurmaktadır. Bu amaçla genellikle mikrodenetleyiciler kullanılsa bile yeni teknolojilerle birlikte SoC (System on Chip-Entegre üzerindeki sistem) devre elemanları kullanılarak işletim sistemi çalıştırabilecek elektronik yapılarının cihazlara entegre edildiği, bilgisayara ihtiyaç duymayan cihazlar da günümüzde geliştirilmiştir.

Fotometrik sistemler temelde absorbands ve reflektans adı verilen iki parametre ile çalışmaktadır. Absorbans madde üzerine düşen ışık akısı ile madde içerisinden geçen ışık akısı arasındaki logaritmik farkın hesaplanması ile ölçülmektedir. Absorbans hesaplaması ile ilgili denklem aşağıda verilmiştir.

$$A = \left(\frac{\Phi_e^i}{\Phi_e^t} \right) = -\log_{10} T \quad (1.1)$$


Burada (Φ_e^i) madde yüzeyi üzerine düşen ışık akısını, (Φ_e^t) madde içerisinden geçen ışık akısını, (T) transmitans (madde içerisinden geçen ışık enerjisi) değerini, (A) ise absorbands değerini ifade etmektedir. Reflektans ise; absorbandan farklı olarak madde üzerinden yansıyan ışık miktarı ölçüm oranıdır. Aşağıda reflektans ölçümünü ifade eden denklem verilmiştir.

$$R = \left(\frac{\Phi_e^r}{\Phi_e^i} \right) \quad (1.2)$$

Denkleme göre (Φ_e^r) madde yüzeyinden yansıyan ışık akısını, (Φ_e^i) madde yüzeyi üzerine düşen ışık akısını, (R) ise reflektans değerini ifade etmektedir.


1.3. Işık Kaynağı Olarak LED Kullanılan Fotometrik Ölçüm Sistemleri

Dedektör olarak LED-fototransistör içeren sistemler; ışık kaynağı olarak LED'in sensör olarak fototransistörün kullanıldığı sistemlerdir. Betteridge ve arkadaşları tarafından geliştirilmiş LED temelli içten akışlı fotodedektör sistemi Şekil 1.2.'de gösterilmiştir. Bu yapıda ışık kaynağı olarak galyum fosfit LED, dedektör olarak silikon temelli fototransistör yer almış olup akış içerisindeki metal iyonlarının tespiti amaçlı kullanılmıştır [73].




Şekil 1.2. LED-Fototransistör Çiftinden Oluşan Transducer Hücresinin Kesit Görüntüsü [70].

Işık kaynağı olarak LED, sensör olarak fotodiyot kullanan dedektör yapılarının kullanıldığı sistemlere Hauser ve Chiang tarafından tasarlanan Şekil 1.3'deki yapı örnek verilebilir. Bu sistem akış enjeksiyon analizi yapabilen bir sistem örneği olarak rapor edilmiştir. Hauser ve Chiang tarafından yapılan çalışmada; spektrofotometrik analiz metotlarında sıkça kullanılan krom, mangan, çinko, demir ve klor üzerinde testler gerçekleştirilmiş ve klasik moleküler absorpsiyon spektroskopisi ile karşılaştırmıştır [74].



Şekil 1.3. LED Fotodiyot Çiftinden Oluşan Transduser Hücresinin Kesit Görünüşü [70].

Işık kaynağı olarak LED, sensör olarak LDR kullanılan dedektörler, LED ve fotodirenç yüzey ile 45° , kendi aralarında 90° açığa sahip olacak şekilde yerleştirilerek reflektans ölçümü yapılan sistemdir. Bu yapıya örnek bir sistemin kesit görüntüsü Şekil 1.4' de gösterilmiştir.




Şekil 1.4. Akış Tipi Sistemde LED-LDR Çifti Kullanımı [70].

Nikel tespitinde [75], farmasötik preparatlar'da reflektans ölçümleri bu tip bir düzenek ile incelenmiş ve oldukça tatmin edici sonuçlar elde edilmiştir [76]. Matthieu Tubino ve arkadaşları çalışmalarında bu reflektans ölçüm sistemini kurarak nikel-dimetilglioksim sisteminin ölçümünde hassas, doğru ve güvenilir sonuçlar elde etmiştir [77].

Çift ışınlı LED optik sensörlerde; özdeş LED ve özdeş sensör kullanılarak referans maddenin ve numunenin beraber ölçülerek değerlendirilmesi hedeflenmiştir. Bu tip ölçüm sistemi Worsfold, P.J. ve arkadaşları tarafından doğal sulardaki fosfat oranını belirlemek amacıyla ilk kez rapor edilmiştir. Yapılan çalışmalarda, iyi bir hassasiyet ve düşük ayıraç (reagent) tüketimi sağlamıştır [61]. Çift ışınlı LED optik sensörün yapısı Şekil 1.5.'de gösterilmiştir.

Bu çalışmalara benzer olarak; iki LED kullanımıyla birlikte renk değişimi düzeltimi, kırılma indisi veya türbidite (bulanıklık, parça yoğunluğu) kullanılarak [78-81] çalışmalar yapılmıştır.

Şekil 1.5’de verilen çift ışınlı LED optik sensöründe; referans tüp içerisinden ölçüm solüsyonu, örnekleme tüpü içerisinden de ölçülmek istenen numunenin enjekte edilmesi ve referans tüpü ile örnekleme tüpünün renk ve bulanıklık olarak karşılaştırılması prensibi ile çalışmaktadır. Bu sistemin en büyük dezavantajı ise herhangi bir kanalda oluşabilecek hava kabarcığının sistemin yanlış değerlendirmede bulunmasına sebebiyet verebilmesidir.




Şekil 1.5. Çift Işınlı LED Optik Sensör Yapısı [70].

Işık kaynağı olarak çoklu LED kullanımında, spektrumun farklı dar bantlı LED'ler ile bölünmesi hedeflenmiştir. LED fotometrelerin önemli bir kısmı, absorbans ölçümleri için spektrumun dar bir alanına odaklanan önceden belirlenmiş bir uygulama için sabit bir dalga boyunun kullanımına dayanır. Bu cihazlarla, dalga boyunda bir değişiklik, genellikle ışık kaynağının fiziksel olarak değiştirilmesini gerektirmektedir. Bu kısıtlama tipik olarak, birden fazla kaynaktan gelen ışığı tek bir detektör hücresine bağlamadaki güçlükten kaynaklanmaktadır [82]. Çoklu LED fotometrelerinin kullanılması ile elektromanyetik spektrumun geniş bir bölgesini LED'leri manuel olarak değiştirmeden birlikte veya ayrı ayrı kaplayabilmesine olanak sağlar [83-89]. Hauser, P.C. ve arkadaşları tarafından geliştirilen sistem 7 farklı LED'in, girişi 7 kanallı, çıkışı 2 kanallı olan fiberoptik kablolarla birleştirilmesi, her kanala ait fiberlerden bir kanalını ölçülmek istenen referans fotodiyotuna, bir diğerini ise numuneye yansıtılması ve logaritmik


farklarının alınması ile absorbans değerlerinin ölçülmesine dayalıdır [82]. Sisteme ait diyagram Şekil 1.6’da verilmiştir.

Bu fotometreler alüminyum, bakır, NH_3 , kalsiyum, krom, fosfat ve nitrit maddelerini kolorimetrik metotlar kullanarak tespit etmek için ayarlanabilmektedir[70].


Yapılan literatür araştırmalarında bazı çalışmalarda ölçüm almak için ikili ve üçlü LED'lerin kullanıldığı görülmüştür. Bu LED'ler birden fazla LED'in tek kılıf altında toplanması ile elde edilmektedir. Farklı çeşitleri olduğu gibi genel olarak ikili LED'ler Yeşil-Kırmızı LED'ler içerirken, Şekil 1.7'deki gibi üçlü LED'ler Kırmızı, Yeşil ve Mavi renkli LED'leri içermektedir. Üçlü LED'lerin ışıklarının karıştırılması sonucu ortaya çıkan ara renkler Şekil 1.8'de gösterilmiştir. Işık kullanılarak ara renkleri oluşturan bu sisteme toplamsal renk sistemi adı verilmiştir [91].



Şekil 1.6. Çoklu LED’li fotometre devre şeması (Kaynaktan uyarlanmıştıır [82].).




Şekil 1.7. Ortak Anot RGB LED'in İç Yapısı [90].



Şekil 1.8. Toplamsal Renk Sistemi.

Akım ayarlaması yapılarak veya PWM (Pulse Width Modulation - Darbe Genişlikli Modülasyon) kullanılarak bu LED'ler renklerini oluşturan ışıkların karışımlarını oluşturabilmektedirler. Ancak LED'lerin dalgaboyları değişmediği için temelde yine aynı dalgaboyunda ışıklar üretmektedirler. Bunlar insan gözünün saniyede 25 kare ve daha fazla resim karesini (fps-frame per second) hareketli görmesinden kaynaklı olarak göz yanılması sonucu olarak farklı renkte görülmektedir.

Işık dedektörü olarak LED kullanan sistemlerde normalde ışık kaynağı olarak kullanılan LED'in dedektör olarak kullanılması için ters kutuplanması gereklidir. Dedektör olarak kullanılan LED sanki bir fotodiyotmuş gibi kullanılarak ölçümler alınır. Şekil 1.9'da kaynaştırılmış LED'ler ve optik probun kesit görüntüsü gösterilmiştir. Bu sistemde iki LED bir kesit yüzeyinden birleştirilmiş ve LED'lerden birisi ışık kaynağı diğeri ise dedektör olarak kullanılmıştır.



Şekil 1.9. (a) Kaynaştırılmış LED'ler (b) Optik probun kesit görüntüsü [92].

Lau ve arkadaşları, çok LED’li fotometreyi, reflektans temelli optik sensör yapısına alternatif olarak geliştirmişlerdir [93]. Bu yaklaşımla çoklu renklerin ve renk karışımlarının analizi yapılabilir hale getirilmiştir [70].

1.4. Yapay Sinir Ağı


Yapay sinir ağları (YSA), genel tabirle insan beyninin çalışma yapısını taklit eden bilgi işleme mekanizmasıdır. İlk yapay sinir ağı Warren McCulloch ve Walter Pitts tarafından 1943 yılında insan beyninin hesaplama yeteneğinden esinlenerek elektrik devreleriyle basit bir sinir ağı modellenmesi ile gerçekleştirilmiştir.

YSA’da sisteme gelen giriş ya da girişler için ağırlıklandırma ve aktivasyon fonksiyonları tarafından üretilen değerlere göre çıkış ya da çıkışlar üretilir. YSA’nın öğrenme fonksiyonu, insan beynini taklit eden yapısı ve paralel çalışma gibi ayrıcalıklı özellikleri bu yaklaşıma olan ilgiyi artırmıştır.

YSA sadece elektronik ve bilgisayar mühendisliği alanında değil biyoloji, kimya, fizik, matematik alanlarında birçok problem üzerine uygulanabilmektedir. Tahmin, sınıflandırma, ayırt etme, saptama gibi konularda hızlı adapte olması ve sistemin öğrenebilir olması sebebiyle kullanılmaktadır. Ancak YSA her ne kadar insan beynini taklit etse de öğrenme konusunda halen eksiklikleri bulunmaktadır ve bunun üzerine çalışmalar halen devam etmektedir. Yapay sinir ağının çalışma mantığını anlayabilmek için insan beynindeki biyolojik yapı incelenmelidir. Bundan sonraki alt bölümlerde bu biyolojik yapılar kısaca özetlenecektir.

1.4.1. Biyolojik Sinir Ağ Yapısı

İnsanın nöron yapısı bilgiyi alan, bu bilgiyi gerekli yere konumlandıran, yorumlayan ve uygun kararı üreten merkez, bu bilgiyi konumlandırılan yerlere taşıyan ve gerekli bilgileri alan uzantılardan ve yapılardan meydana gelmektedir. Şekil 1.10.’da görüldüğü üzere bir nöron çekirdek (nükleus), dentrit, akson ve hücre gövdesinden meydana gelmektedir.




Şekil 1.10. Biyolojik sinir hücresi ve bağlantıları [94].

Sinir hücresi, sinapslardan dentritler vasıtasıyla aldığı bilgiyi aksonlar üzerinden sinapslara taşımaktadır. Bu noktada dentritler birden fazla sinir hücresi ile bağlantıda bulunabilirler. Sinapslar, sinir hücreleri arasında bulunan özel bağlantı noktaları olup nörotransmitter maddeler vasıtası ile bir sinir hücresinden bir başka sinir hücresine bilgi aktarımı sağlar. İnsan vücudunda bulunan milyarlarca nöronun oluşturmuş olduğu sinir ağı insanın sinir sistemini oluşturmaktadır. Biyolojik sinir ağındaki bulunan bu yapıların, YSA'ya uyarlanan karşılıkları Tablo 1.2'de verilmiştir [95].

Tablo 1.2. Biyolojik Sinir Sisteminin Yapay Sinir Ağı Karşılığı

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci eleman
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Yapay nöron çıkışı
Sinapslar	Ağırlıklar

Bir yapay sinir hücresi Şekil 1.11.'de görüldüğü üzere girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olmak üzere beş kısımdan oluşmaktadır. Şekil 1.11. üzerindeki (X)'ler girişleri, (y) çıkışı, (f) fonksiyonu, (n) çıkış sayısını, (W) ise ağırlıkları, (b) bias değerini ifade etmektedir ve çıkış nöronuna giren sinyalin genel eşitliği denklemdeki gibi verilebilir. Burada (x_j) giriş matrisi ve (w_j) giriş matrisidir.



Şekil 1.11. Yapay Sinir Ağının Matematiksel Modeli

$$y_i = \sum_{j=1}^N x_j w_j + b_i \quad (1.3)$$

$$x_j = [X_1 \ X_2 \ X_3 \ \dots \ X_N] \quad (1.4)$$

$$w_j = [w_1 \ w_2 \ w_3 \ \dots \ w_N] \quad (1.5)$$

$$y = f(y_i) \quad (1.6)$$

Denklem sistemleri incelendiğinde, girişlerin kendisine ait ağırlığı ile çarpıldığı ve çarpım sonuçlarının toplamının alındığı görülmektedir. Elde edilen toplam, aktivasyon fonksiyonu adı verilen fonksiyonundan geçirilmektedir. Aktivasyon fonksiyonu yapay sinir ağına göre; doğrusal, tanjant hiperbolik, sigmoid gibi fonksiyonlardan seçilebilmektedir. Genel olarak bu fonksiyon, sistemin girdi ve çıktı yapısına göre seçilmektedir. Örneğin eğer problem doğrusal ise, doğrusal aktivasyon fonksiyonu seçilmesi sistem performansı açısından daha iyi olacaktır.

1.4.2. Yapay Sinir Ağının Avantajları

1. Öğrenme

Yapay sinir ağı modelinin en önemli avantajlarından olan öğrenme fonksiyonu sayesinde sistem tanımadığı girdi ve çıktılar için kendi içerisinde fonksiyon üretmektedir. Bu sayede giriş ve çıktı arasındaki bağıntı bilinmeksizin sonuca ulaşabilmek mümkün olmaktadır. Ancak YSA için gerekli öğrenme verisi doğru ve yeterli olarak verilmelidir. Aksi takdirde öğrenme yanlış ya da eksik olarak gerçekleşeceğinden sonuçlar istenildiği gibi olmayacaktır. YSA'nın bu özelliğini kullanabilmek için YSA'da öğrenme algoritması kullanılmalıdır. Sistemin karakteristiğine göre uygun aktivasyon fonksiyonu seçilmelidir.

2. Tahminde Bulunma

Yapay sinir ağı'nın sadece eğitim verisi ile çalışması gerekmeyip, üretilecek farklı girdiler için farklı sonuçlar gözlemlenebilmektedir. Bu noktada verilecek girdinin eğitim verisi ile uyumlu olması önem arz etmektedir. Örneğin bir yapay sinir ağı, bir sistemin mesafe verileri için eğitilmişse ve sisteme girdi olarak sistemde kullanılan numunenin ağırlık verisi için tahminde bulundurulursa yapay sinir ağı'nın doğru sonuçlar üretmesi beklenmemelidir. Sistem karakteristikleri belirli bir eşik değerinden sonra değişiyorsa ve sistem eşik değeri altı veriler ile eğitilmişse sistemde üretilen çıkışların gerçek değerlerden uzaklaşması olasılık dahilindedir.

3. Uyum Sağlama

Yapay sinir ağı değişken parametrelili sistemler için tekrar kullanılabilir. Kullanılacak olan eğitim parametrelerinde yapılacak güncellemelere ya da eklemelere göre sistem tekrar eğitilebilir ve böylece sistem probleme çözüm getirecek hale getirilebilir. Yapay sinir ağı istenirse otonom olarak probleme karşı, gerçek zamanlı olarak kendisini eğitebilecek şekilde yapılandırılabilir.

4. Paralel Çalışma

Yapay sinir ağı diğer algoritmalarından farklı olarak paralel çalışma özelliğine sahiptir. İnsan beyninin paralel işlem yapma kabiliyeti yapay sinir ağı'nda da olduğu için problemin çözülebilmesi oldukça hızlıdır.

5. Gerçekleştirilebilir Tasarım Yapısı

Yapay sinir ağı için gerekli olan paralel işleme yeteneği bugün birçok sistemde mevcut hale gelmiştir. FPGA (Field Programmable Gate Array - Alanda Programlanabilir Kapı Dizileri) olarak isimlendirilen, üzerinde programlanabilir halde yüzbinlerce hatta milyonlarca kapı elemanı bulunan entegreler sayesinde paralel programlama yapabilmek mümkündür. Günümüzde paralel çalışma yapısı çoklu görev yapısında programlar yazılarak mikrodenetleyiciler ve gömülü sistem işlemcileri üzerinde de çalıştırılabilmektedir. Bazı robot teknolojilerinde kararsızlık durumlarının çözülmesi ve işlem yükünün azaltılması amacıyla kullanılmaktadır.

6. Doğrusal Olmayan Sistem Yapısı İçerebilmesi

Yapay sinir ağı doğrusal olmayan aktivasyon fonksiyonlarını ihtiva eder. Sigmoid, tanjant hiperbolik gibi fonksiyonlar sayesinde doğrusal olmayan veri yapılarında da rahatlıkla kullanılabilir. Bu sayede doğrusal olmayan veriler için doğrusal benzetim oluşturulması gerekmeden kullanılabilir.

1.4.3. Yapay Sinir Ağının Dezavantajları

Yapay sinir ağı kullanımı her ne kadar bazı avantajları da olsa dezavantajları da bulunmaktadır.

1. Dışarıya Kapalı Sistem Yapısı

Yapay sinir ağı ve benzeri algoritmalar kara kutu (black box) sistemler olarak isimlendirilirler. Genel olarak sistemin probleme üretmiş olduğu çözümün neden ya da nasıl olduğu konusunda bilgi edinilemez. Benzer şekilde belirli değerler için üretilen sonucun gerçekte olması gerekenden uzaklaşması durumu açıklanamamaktadır. Sistemin bu türde kapalı çalışmaya sahip olması sebebiyle sistem ne kadar iyi olursa olsun, sisteme tam olarak güvenilememektedir.

2. Belirli Yapay Sinir Ağı Üretme Yöntemlerinin Olmaması

Yapay sinir ağlarında ağ deneme yanılma sonucunda üretilir. Ağın oluşturulması için belirli bir yöntem yoktur. Deneme yanılma sonucunda üretilen ağ yapısı sonucunda optimum bulunması gereken ağırlıklar bulunamayarak sonuçtan uzaklaşma ya da eğitim verilerinin ezberlenmesi gibi durumlar ile karşılaşılabilir.

3. Belirli Yapay Sinir Ağı Parametrelerini Belirleyecek Bir Yöntemin Olmaması

Yapay sinir ağı parametrelerinin belirlenmesinde belirli yöntemler yoktur. Yapay sinir ağının parametreleri olan öğrenme katsayısı, momentum, eğitim tekrarı sayısı gibi parametrelerin belirlenmesinde belirli bir yöntem bulunmamaktadır. Bu durum aynı problem için farklı çözümler getirebilmektedir.

4. Verilerin Uygunlaştırılması Zorunluluğunun Olması

Öğrenilecek probleme ait verilerin ağa gösterimi sayısal değerler olmalıdır; çünkü YSA'lar sayısal veriler ile çalışabilmektedirler. O nedenle sayısal olmayan değerler yapay sinir ağına tanıtılmadan önce sayısal değerlere çevrilmek zorundadırlar. Burada belirlenecek filtre yapısı ağın başarısını etkileyebilmektedir.

1.4.4. Yapılarına Göre Yapay Sinir Ağı

Yapay sinir ağları, nöronların birbirine olan bağlantı şekline göre ileri beslemeli ve geri beslemeli olarak ikiye ayrılır. İleri beslemeli YSA'da nöronlar sadece bir sonraki nöron ve katmanlara bağlanacak şekilde düzenlenmişlerdir. Giriş katmanında bulunan nöronlar, ara katmanlara, ara katmanlar çıkışa bağlı olacak şekilde tek yönlü yapısı vardır. Geri beslemeli tipteki yapay sinir ağlarında ise bağlantı düzenli bir yönde olmayıp, kendisinden önceki katmana, kendi katmanındaki başka bir sinir ağına ya da kendisinden sonraki bir nörona bağlantı oluşturabilir. Bu sayede ağ dinamik bir yapıya bürünmüş olmaktadır.

1.4.5. Yapay Sinir Ağı Öğrenme Metotları

Yapay Sinir Ağı öğrenme metoduna göre; danışmanlı, danışmansız ve takviyeli olmak üzere üç gruba ayrılabilir. Danışmanlı öğrenmede; YSA'yı eğitilirken verilen giriş değerlerinin yanında, çıkış değerlerinin ya da sınıfının verildiği öğrenme şekline danışmanlı öğrenme adı verilir. Ağ, verilen giriş değerlerine karşılık çıkış değerlerine göre ağırlıklarını düzenler. Ağın çıktısındaki hata miktarına bakılarak ağırlıklar tekrar düzenlenir. Danışmansız öğrenmede; YSA'ya eğitim amacıyla sadece girdiler verilir. Çıktılar verilmeden oluşturulacak bu yapı ile veriler yapay sinir ağının kendisi tarafından ilişkilendirilerek sınıflandırılır. Takviyeli öğrenmede ise, YSA'ya eğitim amacıyla girdiler verilir. Her iterasyon sonucunda elde edilen sonucun iyi ya da kötü olduğu ağın kendisine öğretir. Ağ bu geri bildirime göre tekrar ağırlıklarını günceller. Bu sayede sadece giriş verisi ile ağ eğitilmiş olur.


1.4.6. Yapay Sinir Ağı ile İlgili Uygulama Modülleri

MATLAB – Tabanlı YSA Modülü

MATLAB (matrix laboratory), çok paradigmalı sayısal hesaplama yazılımı ve dördüncü nesil programlama dilidir. Bir programlama dili olan MATLAB, MathWorks tarafından

geliştirilmektedir. MATLAB kullanıcıya, matris işleme, fonksiyon ve veri çizme, algoritma uygulama, kullanıcı arayüzü oluşturma, C, C++, Java, ve Fortran gibi diğer dillerde yazılmış programlarla arabağlama imkanı tanır [96].

MATLAB üzerinde bulunan Sinir Ağı Araçları (Neural Network Toolbox) sayesinde yapay sinir ağı ile ilgili analizler gerçekleştirilebilmektedir. MATLAB’de yapay sinir ağına giriş sağlamak için “nnstart” komutu yada “nntool” komutları kullanılabilir. Ancak “nnstart” komutunun sahip olduğu grafiksel tasarım, örüntü tanıma, kümeleme gibi ek özelliklerinin olmasından dolayı “nntool” komutunun kullanımı MATLAB tarafından tavsiye edilmemektedir [97]. “nnstart” komutuna ait MATLAB arayüzü Şekil 1.12’de verilmiştir. Buna göre problemin tipine göre istenilen seçim yapılarak veriler yüklenebilmekte ve analiz gerçekleştirilebilmektedir. Temel problem başlıkları “ giriş-çıkış ve eğri uydurma”, “desen tanıma ve sınıflandırma”, “kümelenme” ve “dinamik frekans dağılımı” şeklindedir. Öğrenmek amacıyla MATLAB üzerinde bulunan örnek veriler istenirse kullanılarak ağ yapısı için ön bilgi edinilebilmektedir.



Şekil 1.12. MATLAB YSA Aracı (nnstart).

WEKA – Tabanlı YSA Modülü

WEKA, makine öğrenimi amacıyla Waikato Üniversitesinde geliştirilmiş ve "Waikato Environment for Knowledge Analysis" kelimelerinin baş harflerinden oluşmuş yazılımın ismidir. Günümüzde yaygın kullanımı olan çoğu makine öğrenimi algoritmalarını ve metotlarını içermektedir. Şekil 1.13'de WEKA'nın giriş arayüzü görülmektedir.



Şekil 1.13. WEKA Yazılımının Arayüzü

WEKA tamamen modüler bir tasarıma sahip olup, veri kümeleri üzerinde görselleştirme, veri analizi, iş zekası uygulamaları, veri madenciliği gibi işlemler yapabilmektedir. WEKA yazılımı, kendisine özgü olarak bir .arff uzantısı desteği ile gelmektedir. Ancak WEKA yazılımının içerisinde CSV dosyalarını da ARFF formatına çevirmeye yarayan araçlar mevcuttur. Temel olarak aşağıdaki 3 Veri Madenciliği işlemi WEKA ile yapılabilir:

- Sınıflandırma (Classification)
- Kümelenme (Clustering)
- İlişkilendirme (Association)

Ayrıca yukarıdaki işlemlere ilave olarak, veri kümeleri üzerinde ön ve son işlemler yapılabilir. Bunlar:

- Veri Ön işleme (Data Pre-Processing)
- Görselleme (Visualization) [98].

WEKA üzerinde günümüze kadar 1000'in üzerinde çalışma olduğu görülmüştür. Veri madenciliği konusunda yeni çalışmalara da rastlanılmaktadır [99].

WEKA'nın sahip olduđu araçlardan birisi de YSA'nın bulunduđu çok katmanlı algılayıcı (multilayer perceptron) algoritmasıdır. WEKA'daki çok katmanlı algılayıcı algoritması sigmoid tipte aktivasyon fonksiyonuna sahiptir. WEKA içerisinde bulunan bazı filtre yapıları ile numerik olmayan verileri işleyebilmek mümkündür. Çapraz doğrulama ve test verisi yükleme özellikleri ağın test edilmesini kolaylaştırmaktadır.

WEKA'da bulunan özellik seçimi algoritmaları ile girdi sayısı fazla olan sistemlerde, giriş verilerindeki sınıfların birbirinden en uzak özelliklerini seçerek kullanıcıya gösterebilir. Bu sayede özelliklerin azaltılması sağlanarak, bir ayırım yapamayacak durumda olan özelliklerin ayıklanması sağlanmaktadır. Bu metotlardan en önemlisi bilgi kazancı (info gain) değerlendiricisinin “ranker” arama metodudur. Ranker arama metodunda, sınıfları birbirinden en fazla ayıran özellik en yüksek rank değerini alarak sıralama gerçekleşmektedir.


Gerçekleştirdiğimiz sistemimizde MATLAB ile birlikte WEKA kullanılarak analizler gerçekleştirilmiş ve sonuçlar değerlendirilmiştir.

2. BÖLÜM

YAPAY SİNİR AĞI DESTEKLİ LED'Lİ FOTOMETRİK SİSTEMİN DONANIMSAL GERÇEKLEŞTİRİMİ


2.1. Sistemin Bileşenleri

Sistem için tasarım yapılırken öncelikle spektrum bölgesinde neredeyse boşluk kalmayacak şekilde ışık kaynağı seçimi ve ışık kaynağının oluşturduğu spektral aralığını kapsayacak bant genişliğine sahip sensör gerekliliği ortaya konulmuştur. Sistem klasik spektrofotometrelerdeki gibi ışık kaynağını tayflara ayırarak ölçüm yapmak yerine ayrık dalga boylu ışık kaynakları ve farklı bant genişliğine sahip sensör yapısı ile geliştirilmiş, mantık olarak matematikteki tümdengelim yerine parçaları birleştirerek tümevarım metodu uygulanmıştır. Sistemin blok diyagramı Şekil 2.1'de gösterilmiştir. Sistemde LED'lerin gerekli konuma getirilmesinde servo motor, LED'lerin sürülmesinde ve portların çoklanmasında I²C haberleşme protokolüne sahip giriş çıkış çoklayıcı (I²C I/O Expander), ışık verisinin okunmasında ışık dijital dönüştürücüsü (Light to digital converter), sistemin donanım kontrolünü gerçekleştirmek için mikrodenetleyici ve son olarak verilerin alınıp YSA ile ağın oluşturulması için bilgisayar kullanılmıştır.




Şekil 2.1. Sistemin blok diyagramı

Ölçüm yapılan sistemin üç boyutlu görüntüsü Şekil 2.2’de verilmiştir. Bu yapıda her bir LED konumlanarak küvetin diğer tarafında bulunan fotodiyotlar üzerine ışık düşürülmektedir. Tasarımda, disk üzerine yerleştirilen devre elemanlarının ön ve arka görünümü Şekil 2.3’de, sistemin önden ve arkadan görünümü ise Şekil 2.4’de verilmiştir.




Şekil 2.2. Sistemin Üç Boyutlu Görüntüsü



Şekil 2.3. Diskin Ön ve Arka Görünümü


Dış ortamdaki ışık kaynaklarından etkilenmemesi için tasarlanan düzenek kapalı kutu içerisine yerleştirilmiştir. Bir madde için en az 10 ölçüm yapılmış ve standart sapma değeri iki üzerindeki ve altındaki ölçümler göz ardı edilerek ölçümlerin ortalaması alınmıştır. Böylece LED’lerin konum hataları, enerji dalgalanmaları hataları ve veri bozulmasına bağlı hatalar en aza indirilmeye çalışılmıştır.



Şekil 2.4. Sistemin Ön ve Arka Görünümü

2.1.1. Işık Kaynağı

Ayrık LED'ler ile tüm bant içerisinde ölçüm yapabilmek için çok fazla sayıda LED'in kullanılması gerekmektedir. Bu nedenle tasarlanan sistemde dar bantlı LED'lerin yanı sıra geniş bant genişlikli fakat tepe dalga boyları farklı LED'ler kullanılmıştır. Örneğin soğuk beyaz ile sıcak beyaz LED'lere ait spektrum grafiği Şekil 2.5'deki gibidir.




Şekil 2.5. Soğuk Beyaz ve Sıcak Beyaz LED'in Spektrumu [98].

Şekildeki spektrumlara göre; mavi-mor bölgenin soğuk beyaz LED'de, 500nm ile 700nm arası bölgenin ise sıcak beyaz LED'de daha yoğun olduğu görülmektedir. Ayrık LED'lerin ulaşamadığı spektrum boşlukları geniş bant genişlikli LED'ler ile kapsanmaktadır. Bu sayede ayrık LED'lerin ulaşamadığı spektrumdaki maddeleri tanıyabilmek açısından oldukça önemli sonuçlar verebilecektir. Bu LED'lerin yanında, pembe renkte ışık veren, normalde bitki yetiştiriciliğinde ultraviyole ışıkla beraber kullanılan geniş bant genişliğine sahip LED'de kullanılmıştır. Pembe bir LED'in

spektrumu Şekil 2.6’da verilmiştir. Böylece dar bantlı LED’lerin ulaşamadığı spektral aralıkta ışık kaynağı oluşturulmuştur.

Bu LED’lerin farklı tepe dalgaboyuna sahip olması sayesinde 3 LED’in kesiştirimi maddenin spektral aralığı ile ilgili ön bilgi sunabilecektir.

Sistem bir adet disk üzerine yerleştirilmiş toplamda 22 adet 365nm~940nm arasında LED ışık kaynağı içermektedir. LED’lerin numaraları ve sahip olduğu tepe dalgaboyları Tablo 2.1’de verilmiştir.



Şekil 2.6. Pembe LED'in Spektrumu [101].

Seçilen LED’ler ticari amaçlı üretilen LED’ler olup teminleri kolaydır. 365nm daha küçük tepe dalga boyuna sahip ticari amaçlı LED’ler bulunmasa bile; özel amaçlı olarak üretilen LED’ler sistem üzerinde kullanılarak çok daha küçük yapıdaki maddelerin analizleri gerçekleştirebilecektir. Her ne kadar üreticileri ve satıcıları bant genişliğini bildirmiş olsalar bile bu bant genişlikleri üretim sürecindeki saflık değerlerine bağlı olduğu için genellikle aynı seri numarasına sahip olmayan LED’ler farklı dalga boyuna sahip olabilmektedirler. Genel olarak incelendiğinde üreticiler, tepe dalga boylarının $\pm 5\text{nm}$ ’ye kadar değişebileceğini, $\pm 30\text{nm}$ ’ye kadar yan ışımaya yapabileceği bildirmişlerdir. LED’lerin spektral dalga boylarının kontrolü için farklı metotlar kullanılmıştır. Thomas S. Kuntzleman ve Erik C. Jacobson tarafından geliştirilen spektral dalga boyundan rengi elde etme yöntemi de bu metotlardan birisidir [102].

Görsel ayırım metotları (görünür renk bölgesindeki LED'lerin ışığının rengi) ve fotoğrafik teknikler bakımından incelendiğinde dalga boylarının ayrı olduğu konusunda bilgi vermektedir. Yan dalga boyları da düşünülerek tasarlanmış olan sistemde amaç maddenin dalga boyunu kesin olarak ölçmek değil maddenin fotometrik yöntemler ile tanınmasıdır. Bu amaçla kullanılan sensörler ile malzemenin o dalga boyuna ait parametrik absorptans ve reflektans verileri incelenecektir. İncelenen bu değerler, LED'lerin dalgaboyları farklı olsa bile aynı içerik için benzer absorptans ve reflektans verileri gösterecektir. Çünkü sistemin kalibrasyonu yine sistem ışık kaynaklarına bağlı olarak yapılacaktır. Kullanılacak malzemenin yoğunluğu, kirleticilerin etkileri sensörlerden farklı ölçümlerin alınmasına neden olacağı için yapay sinir ağı ile maddenin karakteristiklerin tespit edilmesi amaçlanmıştır. Ayrıca her madde için tüm dalga boyundaki ışıklar anlamlı olmayıp ölçülecek maddenin cinsine göre ışığın spektral dalga boyu aralığı ve reflektans ya da absorptans değerleri önem kazanmaktadır.

Tablo 2.1. Kullanılan LED'lerin Tepe Dalgaboyları

No	Dalga Boyu	No	Dalga Boyu
1	Soğuk Beyaz	12	505-510nm
2	Sıcak Beyaz	13	515-525nm
3	Pembe	14	570nm
4	365nm	15	580-590nm
5	370-375nm	16	590-600nm
6	375-380nm	17	620nm
7	390-395nm	18	620-630nm
8	395-400nm	19	850nm
9	400-405nm	20	880nm
10	460-465nm	21	940nm
11	490-500nm	22	950nm


Bu problemlerin, yapay sinir ağı ve özellik seçimi kullanılarak ortadan kaldırılabileceği düşünülmüştür. Ayrıca sisteme farklı maddelerin öğretilmesi ile istenilen maddelerin tanınmasında kullanılabilecektir.

Mekanik disk üzerindeki LED'ler bir servo motor vasıtası ile konumu değiştirilmekte ve aktif olan ilgili LED üzerinden parametrik absorptans ve reflektans ölçüm değeri alınmaktadır. LED'lerin yerleşim aralığı 7.5 derece olmasına rağmen LED konumları tek tek çıkarılarak bir dizi olarak tanımlanmış ve konumlar bu dizi üzerinden

okunmuştur. Bu sayede LED'lerin tam konumlarına ya da ulaşılacak en optimum konuma ayarlanmıştır.


LED'lerin beslemesinde kullanılan direnç değerleri, kızılötesi LED'ler hariç olmak üzere 20mA altı çalışmaya uygun olacak şekilde seçilmiştir. Kızılötesi LED'ler 40mA'e ihtiyaç duymakta ancak kullanılan I²C sürücüsü maksimum 25mA'de çalışabileceği için 24mA'de çalışabilecek şekilde direnç seçimi yapılmıştır. Kızılötesi LED'lerin 24mA'de daha sönük ancak yeterli miktarda yandığı, kızılötesi filtresi bulunmayan kamera ile tespit edilmiştir. Ancak daha sönük olsa bile üretilen ışımanın yeterli olabileceği görülmüştür.

LED'lerin sürülmesinde kullanılan Philips firmasının üretmiş olduğu PCF8574; giriş/çıkış sayısını artırmak için üretilmiş, 3 adet adresleme pini ile 8 adede kadar I²C haberleşmesi ile aynı hat üzerinde kullanılabilir, her biri 8 giriş/çıkışa sahip olan entegredir. Bu entegrenin kullanım amacı hareketli olan LED'lere 4 bağlantı ile (V_{cc}, GND, SDA ve SCL) erişim sağlayarak 22 LED'i kontrol etmektir. Burada kaydıran yazmaç (shift register) kullanılmamasındaki temel amaç senkronizasyon problemlerinin önüne geçmektir. Kaydıran yazmaçlarda, sistemin hareketi sırasında ya da motor gürültüsü sebebiyle oluşabilecek gerilim dalgalanmaları, aktif olan LED'den sonraki ve ya önceki LED'lerin aktif olmasına yol açabilmektedir. Bu problemin oluşmasını önleyebilmek için, adreslenebilen bir giriş/çıkış entegresi kullanılmasının daha kesin sonuçlar vereceği düşünülmüştür. PCF8574, mandal (latch) yapısına ve 2.5V~6V arasında çalışma gerilimine sahip olduğu için doğrudan LED sürme yeteneğine sahiptir. Entegrenin karakteristiği gereği sink bir sürücü olarak çalışmaktadır, çünkü lojik 1 çıkış seviyesinde en fazla 100µA besleme sağlarken, lojik 0 çıkış seviyesinde 25mA akımın üzerinden akmasına vermektedir. Entegreye ait blok diyagram Şekil 2.7'de gösterilmiştir. Buna göre entegre içerisinde filtrelerin, mantıksal kesme (logic interrupt) modülünün, I²C BUS kontrolcüsünün, açılış sıfırlama modülünün ve giriş/çıkış portlarının olduğu görülmektedir. Sistemde kullanılan filtreler gelen dijital sinyallerin yanlış değerlendirilmesini önleme amacıyla kullanılmıştır. Açılış sıfırlama modülü ise, modüle enerjisi verildiğinde hata sonucu giriş/çıkış oluşturmamak için kullanılmıştır. Bu modüllerin entegre içerisinde kullanılması ile sistemin açılışı sırasında yanlış LED'lerin aktif edilmesi problemleri ile karşılaşılmasıdır.




Şekil 2.7. PCF8574 Blok Diyagramı [103].


Her bir giriş/çıkış için basitleştirilmiş iç şeması Şekil 2.8’de gösterilmiştir. Adres yapısı PCF8574 ve PCF8574A modelleri için farklılık göstermektedir. Şekil 2.9.’da PCF8574 için Şekil 2.10.’da PCF8574A için adres yapısı görülmektedir.



Şekil 2.8. PCF8574 için her bir Giriş/Çıkış için basitleştirilmiş iç devre şeması [103].




Şekil 2.9. PCF8574 Adres Yapısı [103].



Şekil 2.10. PCF8574A Adres Yapısı [103].

Burada A2, A1 ve A0 adres pinlerinin lojik seviyelerini temsil etmektedir. Buna göre çıkarılan veriler ile onaltılık tabana dönüştürülerek sonrasında byte olarak veriler gönderilmektedir.

Entegrenin pinlerinde hem dijital okuma hem de dijital çıkış verme özelliği olmasına rağmen sadece dijital çıkış verme özelliği kullanılarak pinlerine bağlı olan LED'in açılması sağlanmıştır. Dijital çıkış verme özelliği Şekil 2.11'deki gibi gerçekleştirilmektedir.




Şekil 2.11. PCF8574 Zamanlama Diyagramı [103]

2.1.2. Sensörler


Sistemde ölçüm almak için TAOS tarafından üretilen TSL2561 sensörü kullanılmıştır. Bu sensörün seçilmesinin en büyük nedeni; kullanılan LED'lerin dalga boyunu kapsayan geniş bantgenişliğine sahip olması ve dijital bir sensör olmasından dolayı kablo uzunluğu gibi faktörlerden etkilenmeden 16-bit derinliğinde ADC ölçümleri alabilmesidir. Sensöre ait spektrum duyarlılığı Şekil 2.12'de verilmiştir. TSL2561, kullanmış olduğu I²C (Inter-Integrated Circuit) haberleşmesi sayesinde aynı hat üzerinde 3'e kadar TSL2561 sensörün kullanımına izin vermektedir. Bunun sebebi sensörde 3 adres seçim yapısının olmasıdır. Bunlar boşta, lojik 1 ve lojik 0 durumlarıdır. Aynı hat üzerine I²C giriş/çıkış çoğullama entegresi olan PCF8574'den 3 adet

bağlanmıştır. Böylece sistemde kablo kirliliğinin ve fazla kablonun sebep olabileceği problemlerin de önüne geçilmiştir.



Şekil 2.12. TSL2561 Sensörünün Spektral Duyarlılığı [104].

TSL2561'in bir diğer avantajı ise her sensör içerisinde iki adet farklı bant genişliğine sahip fotodiyot barındırmasıdır. Bu fotodiyotlardan (0.) kanala sahip olanın bant genişliği oldukça büyük iken (1.) kanala sahip olan LED'in bant genişliği küçük ve kızılötesi ölçüm spektral aralığındadır. İki kanalın ortak kullanımıyla algılanan ışığın, kızılötesi bölgeye mi, yoksa görölür bölgeye mi tekabül ettiği saptanabilmektedir. Sensörün iç yapısını gösteren blok diyagram Şekil 2.13.'de gösterilmiştir.



Şekil 2.13. TSL2561'in Blok Diyagramı [104].

Sensör üzerinden alınan veriler ADC sayı değeri cinsinden olup istenirse birim alana düşen ışık şiddeti birimi olan L $\ddot{u}$ x cinsinden hesaplanabilmektedir [104]. Bu hesaplamalar aşağıdaki denklem takımıyla ifade edilir.

$$0 < K_1/K_0 \leq 0,50 \quad \rightarrow \text{Lüx} = 0.0304 \times K_0 - 0.062 \times K_0 \times ((K_1/K_0)^{1.4}) \quad (2.1)$$

$$0,5 < K_1/K_0 \leq 0,61 \quad \rightarrow \text{Lüx} = 0.0224 \times K_0 - 0.031 \times K_1 \quad (2.2)$$


$$0,61 < K_1/K_0 \leq 0,80 \quad \rightarrow \text{Lüx} = 0.0128 \times K_0 - 0.0153 \times K_1 \quad (2.3)$$

$$0,80 < K_1/K_0 \leq 1,30 \quad \rightarrow \text{Lüx} = 0.00146 \times K_0 - 0.00112 \times K_1 \quad (2.4)$$

$$K_1/K_0 > 1,30 \quad \rightarrow \text{Lüx} = 0 \quad (2.5)$$

Burada (K_0) kanal-0'dan alınan ADC sayı değerini, (K_1) ise kanal-1'den alınan ADC sayı değerini göstermektedir. TSL2561'in ışık ölçüm aralığı 0 - 65535 ADC sayı değeri arasında yer almaktadır. Bu değerler lüx birimine çevrildiğinde ölçüm hassasiyeti azaldığından dolayı sistem ölçümlerinde Lüx birimli parametrelerle birlikte ADC sayı değerleri de kaydedilmiştir. Böylelikle çok küçük değişiklikler bile fark edilebilmiştir.

TSL2561 içerisinde bulunan fotodiyotlar farklı açılardan gelen aynı miktardaki ışığı farklı güçlerde algılayabilmektedir. Bu durum fotodiyotların açısız yer değiştirmesi (angular displacement) olarak bilinmektedir. Sensörün açısız yer değiştirmesine ait grafik Şekil 2.14'de verilmiştir.




Şekil 2.14. TSL2561 sensörünün açısız yer değiştirmesi grafiği [104].

Her LED'in ışık şiddeti 65535 ADC sayısını görememektedir, ancak bu ölçümler açısından sorun teşkil etmemektedir. Çünkü sistem her LED için boş kuvvet ölçümünü alarak maksimum parlaklık değerini de kaydetmektedir.

2.1.3. Kontrol Ünitesi

Sistemde mikrodenetleyici olarak Atmel şirketinin üretmiş olduğu Atmega328P-AU entegresinden faydalanılmıştır. Bu entegre arduino nano üzerinde kullanılmaktadır. Genel olarak 8 adet analog girişe ve 14 dijital giriş/çıkışa sahiptir. Dijital giriş/çıkışlardan 6'sı donanımsal darbe genişlikli modülasyon (PWM) özelliğine sahiptir. Bunların yanında donanımsal olarak bir adet seri iletişim (UART), bir adet I²C ve bir adet SPI haberleşme portuna sahiptir. Analog pinleri 10bit'lik ADC (Analog to Digital Converter)'a sahiptir. İçerisinde 1KB'lık EEPROM'a (Electrically Erasable Programmable Read-Only Memory), 32KB flash hafızaya ve 2KB SRAM'e (Static Random Access Memory-Durağan Rastgele Erişimli Bellek) sahiptir. Sistem üzerinde bulunan FTDI şirketine ait USB seri dönüştürücü entegresi ile bilgisayar ile bağlantı kurabilmektedir. Bu sayede MATLAB gibi numerik analiz programlarında veri toplama aygıtı (data acquisition device) olarak kullanılabilir. Bunun yanında sistemde 3.3 volt regülatörünün olması ve harici çıkış olarak bu gerilimin kullanılması sayesinde 3.3V besleme ile çalışan sistemler ek besleme ihtiyacı olmaksızın çalışabilmektedir. Sistemde kullanılan sensörlerin ve port çoğullayıcıların haberleşmesi için I²C bağlantı yapısı tercih edilmiştir. Sistemin genel I²C bağlantısı blok yapısı Şekil 2.15.'de tanımlanmıştır. Arduino Nano'nun görüntüsü Şekil 2.16'da verilmiştir.



Şekil 2.15. Tasarlanan Sistemdeki I²C Bağlantısı

Bu kartın kullanılmasının en büyük sebebi; sahip olduğu minimal boyutlar ve sağlanan ücretsiz yazılım geliştirme platformudur. Açık kaynak kodlu programlamaya sahip


olması sebebiyle çok geniş yazılımsal kütüphaneleri bulunmaktadır. Akademik çalışmalarda da oldukça sık başvurulmaktadır.



Şekil 2.16. Arduino Nano kartının görüntüsü

2.1.4. Motor

Sistemde hareket mekanizması için Dynamixel AX-12A servo motor kullanılmıştır. Bu servo motor diğer servo motorlara göre yarı çift yönlü (half duplex) seri haberleşme tipine sahip olması, daha 0.29 açısal derecede adım aralıklı olması, konum bilgisinin motor üzerinden okunması gibi avantajlara sahiptir. Dijital haberleşme sayesinde hassas PWM üretimi gerekmemektedir. Bu da konumlanmanın iyileştirilmesi konusunda oldukça önemli sonuçlar vermiştir. Sistemin ilk tasarımı MG995 servo motoruyla yapılmıştır. Ancak hassas pozisyonlama yapılamaması, dişli boşluklarının sonuçları olumsuz yönde etkilemesi sebebiyle değiştirilmiştir. Sistemdeki LED sayısının artırılmasına engel teşkil edebilecek MG995'deki 180 açısal derecelik hareket AX-12A ile birlikte 300 açısal derceye çıkarılmıştır. Bu sayede diskin çapı değiştirilmeden 40 adede kadar LED yerleştirilebilecektir. Şekil 2.17'de AX-12A'ya ait pin yapısı görülmektedir.



Şekil 2.17. Dynamixel AX-12A pin yapısı

AX-12A'nın tek başına mikrodenetleyici ile kontrol edilebilmesi için ek devre kurma ihtiyacı gerekmektedir. Bunun sebebi mikrodenetleyicilerde genel olarak yarı çift yönlü

değil, tam çift yönlü (full duplex) seri iletişim desteklenmesidir. Tam çift yönlü iletişimde gelen verinin alınması için RX, veri göndermek için TX pinleri bulunmaktadır. Oysa ki half duplex seri iletişimde yalnızca tek bir data pini bulunmaktadır ve bu pin üzerinden veriler hem gönderilip hem de alınmaktadır. Bu nedenle gelen veriyi RX'e yönlendirmek giden veriyi de aynı hat üzerine yönlendirmek gerekmektedir. Bunun için üç durumlu buffer entegresi olan 74HLS241 kullanılmıştır.

2.1.5. Bilgisayar Arayüzü

Sistem ilk başta aldığı boş ölçüme göre ışık şiddetindeki değişimi, parametre olarak belirlemektedir. Belirlenen bu parametreler, maddenin optik kimliği olarak kayıt edilmektedir. Bu sayede maddenin tekrar ölçümünde referans madde ölçümüne tekrar ihtiyaç duymamakta, bu da sistemin daha rahat ve daha güvenli olarak tespit edebilmesini sağlamaktadır. Sistemin referans maddeyi kaydetmesi ile:

- Referans madde ayarlanmasında derişimindeki değişikliklerden kaynaklanabilecek hatalar,
- Referans maddenin beklemesi ile ilgili çökme ve buharlaşma problemlerine ilişkin hatalar,
- Referans maddenin bozulması veya zaman içerisindeki kimyasal reaksiyonlarına ilişkin hatalar,
- Referans maddenin saklanması ile ilişkin hatalar elimine edilerek daha doğru sonuçlar elde edilebilecektir.

Ayrıca sistemin taşınabilir yapısı sayesinde yerinde ölçüm alınması daha hızlı, daha güvenilir sonuçların elde edilebilmesine olanak sağlayacaktır.

Sistemdeki parametrik absorbans ölçümü, matrissel olarak boş kuvvet transmittans ölçümlerinden numunenin içerisinde geçen LED ışığının şiddeti çıkarılarak elde edilmiştir. Bu noktada logaritması alınmadan sanal bir absorbans ve reflektans parametresi oluşturulmasının sebebi; küçük ondalıklı sayılarla hesap yapmanın, büyük sayılarla işlem yapmaktan veri işleme açısından daha zor olmasıdır. Absorbans ölçümü için kullanılan ifade, Denklem 2.6'da verilmiştir.

$$P_A = P_{KA} - P_{NA} \quad (2.6)$$

Denklemden (P_A) parametrik absorptans değeri matrisi, (P_{KA}) parametrik boş küvet ölçümü matrisini ve (P_{NA}) parametrik numune ölçüm matrisini belirtmekte olup, aşağıdaki denklem takımıyla tanımlanmaktadır.

$$P_A = [ADC_{LED1}, ADC_{LED2}, ADC_{LED3}, \dots, ADC_{LED22}] \quad (2.7)$$

$$P_{KA} = [ADC_{LED1}, ADC_{LED2}, ADC_{LED3}, \dots, ADC_{LED22}] \quad (2.8)$$

$$P_{NA} = [ADC_{LED1}, ADC_{LED2}, ADC_{LED3}, \dots, ADC_{LED22}] \quad (2.9)$$

Bu matrisler görülebilir bölgede ölçümler için, kızılötesi bölgesindeki ölçümler için, full bant ölçümler için ve hesaplanmış lüks ölçü birimi için ayrı ayrı kullanılmıştır. Böylece;

$$P_{AI} = P_{KAI} - P_{NAI} \quad (2.10)$$

$$P_{AV} = P_{KAV} - P_{NAV} \quad (2.11)$$

$$P_{AF} = P_{KAF} - P_{NAF} \quad (2.12)$$

$$P_{AL} = P_{KAL} - P_{NAL} \quad (2.13)$$

denklemleri elde edilmiştir. Kızılötesi bölge (I), görölür bölge (V), full bant (F), Lüks cinsinden olan ölçümler (L) son eki ile ifade edilmişlerdir.

Reflektans ölçümü ise; bir başka sensör üzerinden numuneden yansıyan LED ışık şiddetinden boş küvet yansıması çıkarılarak elde edilmektedir ve aşağıdaki denklem takımıyla tanımlanmaktadır.

$$P_R = P_{NR} - P_{KR} \quad (2.14)$$

Bu denklemden (P_R) parametrik reflektans değeri matrisini, (P_{KR}) parametrik boş küvet ölçümü matrisini ve (P_{NR}) parametrik numune ölçüm matrisini belirtmektedir ve aşağıdaki denklem takımıyla tanımlanmaktadır.

$$P_R = [ADC_{LED1}, ADC_{LED2}, ADC_{LED3}, \dots, ADC_{LED22}] \quad (2.15)$$

$$P_{KR} = [ADC_{LED1}, ADC_{LED2}, ADC_{LED3}, \dots, ADC_{LED22}] \quad (2.16)$$

$$P_{NR} = [ADC_{LED1}, ADC_{LED2}, ADC_{LED3}, \dots, ADC_{LED22}] \quad (2.17)$$

Absorbans ölçümlerinde olduğu gibi, bu matrisler görülebilir bölge, kızılötesi bölge, full bant bölge ölçümleri ve hesaplanmış lüx ölçü birimi için ayrı ayrı kullanılmıştır. Böylece:

$$P_{RI} = P_{KRI} - P_{NRI} \quad (2.18)$$

$$P_{RV} = P_{KRV} - P_{NRV} \quad (2.19)$$

$$P_{RF} = P_{KRF} - P_{NRF} \quad (2.20)$$

$$P_{RL} = P_{KRL} - P_{NRL} \quad (2.21)$$


denklemleri elde edilmiştir. Bu değerler kullanılan yapay sinir ağının girdilerini oluşturmaktadırlar.

2.2. Verinin Alınması ve İşlenmesi

Sistemde verilerin anlamlı bir şekle dönüştürülmesi mikrodenetleyici tarafından sağlanmaktadır. I²C protokolünde sensörlerin register'larındaki bitler önce byte'a daha sonrasında byte verileri numerik sayı değerlerine dönüştürülmektedir. ADC sayı değeri de bu noktada lüx birimine dönüştürülmektedir. Dönüştürülen bu değerler, mikrodenetleyicinin RAM kısmında saklanmakta, ölçüm bittiğinde de seri-usb iletişim ile veriler bilgisayardaki MATLAB programına aktarılmakta ve veriler MATLAB tarafından matris olarak tutulmaktadır. MATLAB, sistemden verilerin alınmasında, ön işlemlerden geçirilmesinde ve ön incelemenin gerçekleştirilmesinde kullanılmaktadır. Verilerin alınması arduino üzerinde bulunan USB-Seri dönüştürücü vasıtasıyla gerçekleştirmektedir. Arduino ile bilgisayar arasında haberleşme bilgisayardaki haberleşme portu (COM Port) vasıtasıyla RS-232 protokolü ile gerçekleşmektedir. Bunun için MATLAB içerisinde uygulamalar (apps) sekmesinde bulunan, Şekil 2.18'de arayüzü gösterilen “aygıt kontrol araç kutusu (instrument control toolbox)” kullanılmıştır.

Aygıt aracı üzerinde arduino nano'nun bağlı bulunduğu haberleşme portu seri iletişim kısmında yer almaktadır. Burada arduino nanonun bağlı bulunduğu haberleşme adresi seçilerek iletişim başlatılmaktadır. Arduino üzerinde yazdığımız koda göre ölçümü başlatmak için “ölç” kelimesini temsilen “o” harfi gönderilerek ölçme işlemi başlatılmaktadır. Aygıt aracı; gelecek paket boyutu, kodlama tipi, iletişim hızı,

doğrulama bit'i, kod büyüklüğü gibi ayarlamalar uygun olarak yapıldıktan sonra, ölçüm için gerekli kod dosyasını oluşturmaktadır. Gelen veriler her ne kadar sayı olsa da haberleşme esnasında tekrar byte'a sonrasında da karaktere dönüştürülmektedir. Oluşturulan bu dosya ile alınan veriler karakterlerin birleşimi şeklinde olan string tipinde olduğu için veriler değişken içerisine alındıktan sonra tam sayı biçiminde sayılara bölünerek önce dizi, sonrasında tam sayı tipinde matris oluşturulması sağlanmıştır. Sistem veri kaybının olup olmadığını anlamak için matris boyutunu kontrol etmekte ve her bir matris alanı için 22 LED ölçümü geldiği doğrulanmaktadır.



Şekil 2.18. MATLAB Ayrıt Kontrol Araç Kutusu Arayüzü

Boş küvet ölçümü, ölçüm hatasının minimum olması adına 20 kez ölçülen boş küvetin standart sapması hesaplandıktan sonra, standart sapmanın 2 katının altındaki ve üzerindeki verilerin sistemden çıkarılıp, kalan verilerin ortalaması alınarak hesaplanmaktadır. Elde edilen boş küvet'e ait transmittans verisinden dolu küvet ölçümü çıkarılmakta ve bu sayede malzemenin üzerinde tutmuş olduğu yani absorb ettiği ışık şiddeti olan absorbans miktarı tespit edilmektedir. Reflektans ise dolu küvet ölçümünden yansıyan ışınlardan boş küvetten yansıyan ışınların çıkarılması ile elde edilmektedir. Elde edilen bu veriler, yine numerik analiz programı olan WEKA tarafından işlenebilmesi adına öncelikle Excel üzerinden CSV dosya formatında kaydedilmektedir. Elde edilen CSV dosyası WEKA'nın kullandığı dosya formatı olan ARFF formatına dönüştürülmektedir.

WEKA geniş algoritma seçeneği, kullanım sadeliği, teknik ölçüm verileri açısından oldukça kullanışlıdır. Sınıflandırma amacıyla yapay sinir ağına ait çok katmanlı algılayıcı algoritması kullanılmıştır.

WEKA’da bulunan çok katmanlı algılayıcı algoritması elle oluşturulabildiği gibi istenirse algoritma tarafından oluşturulabilir veya her iki şekilde de yapılabilmektedir. Eğitim esnasında yapay sinir ağı görüntülenebilmekte de değiştirilebilmektedir. Sınıfın sayısal değer olduğu durumlar haricinde düğümlerin tamamı sigmoid yapıdadır. Sınıf sayısal olduğunda çıkış düğümleri eşi olmayan doğrusal birimler haline gelir [105].

WEKA içerisindeki çok katmanlı algılayıcı algoritmasına ait temel parametre tanımları aşağıda özetlenmiştir.

Otomatik Yapılandırma (autoBuild): YSA’da ara katmanlar ile olan bağlantıyı otonom şekilde oluşturulmasını sağlar.

Toplu İş Boyutu (batchSize): Toplu tahmin gerçekleştirildiğinde tercih edilen örnek sayısını ifade etmektedir. Toplu iş boyutu için daha fazla veya daha az örnek sağlanabilir. Bu parametre, uygulamalara tercih edilen bir toplu iş boyutunu belirtme fırsatı vermektedir.

Azaltma (decay): Öğrenme oranının düşmesine neden olacaktır; çünkü bu parametre başlangıç öğrenme oranını, mevcut öğrenme oranının ne olması gerektiğini belirlemek için başlangıçtaki öğrenme oranı ile çevrim sayısına bölecektir. Bu, ağı hedef çıktıdan farklılaşmasını durdurmanın yanı sıra genel performansı geliştirmeye yardımcı olabilmektedir. Azalan öğrenme oranının görüntülenmeyeceğine, yalnızca orijinal öğrenme oranı olan grafik kullanıcı arayüzünde gösterileceğine dikkat edilmelidir. Öğrenme hızı, grafik kullanıcı arayüzünde değiştirilirse, başlangıç öğrenme oranı olarak kabul edilir.

Yetenekleri Kontrol Etme (doNotCheckCapabilities): Bu seçenek aktif edilirse sınıflandırıcı inşa edilmeden önce, sınıflandırıcı yetenekleri kontrol edilmemektedir.

Gizli Katmanlar (hiddenLayers): YSA’daki gizli katman sayısını ifade eder. “0” olması durumunda gizli katman oluşturulmaz, pozitif tam sayı girilmesi durumunda da sayı adedince gizli katman meydana getirilir. Bu seçenek sadece otomatik yapılandırma aktif ise gerçekleştirilebilen seçeneklerden birisidir. WEKA’ya özel bazı tanımlama

fonksiyonları geliştirilmiştir. Gizli katman seçeneğine “a” harfi girilmesi durumunda özellik sayısı ile sınıf sayısının toplamının yarısı kadar, “i” harfi girilmesi durumunda özellik sayısı kadar, “o” harfi girilmesi durumunda sınıf sayısı kadar “t” harfi girilmesi durumunda ise özellik ve sınıf sayısının toplamı kadar gizli katman meydana getirilir.

Öğrenme Oranı (learningRate): Ağırlıkların güncellenen miktarının belirlendiği parametredir.

Momentum (momentum): Momentum katsayısı ağırlık öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlayan parametredir [106].

İsim Kökenliden İkili Sayısal Sisteme Dönüştüren Filtre (nominalToBinaryFilter): Tüm nominal (isim kökenli) özellikleri ikili sayısal özelliklere dönüştüren bir yapıdır. Verilerde nominal (isim kökenli) özellikler varsa bu seçenek, performansı artırmaya yardımcı olabilmektedir.

Özellikleri Normalize Et (normalizeAttributes): Verilere ait özellikleri -1 ile 1 arasına getirerek normalize etmek için kullanılan parametredir. Bu seçenek ağırlık performansını artırabilmektedir.

Nümerik Sınıfları Normalize Et (normalizeNumericClass): Verilere ait sınıfları -1 ile 1 arasına getirerek normalize etmek için kullanılan parametredir. Bu seçenek ağırlık performansını artırabilmektedir. Orijinal aralıklar ölçeklenerek korunmaktadır.

Sayının Ondalık Yeri (numDecimalPlaces): Modeldeki sayıların çıkışı için kullanılacak ondalık basamakların sayısını ifade etmektedir.

Sıfırlama (reset): Öğrenme oranı düşük olduğunda, ağırlık otomatik olarak sıfırlanmasını ve ağırlık tekrardan eğitilmesini sağlar. Bu seçenek grafiksel kullanıcı arayüzü aktif değilse çalışmaktadır. Yapay sinir ağı ıraksar, ancak sıfırlanmasına izin verilmezse, eğitim sürecinde başarısız olur ve bir hata mesajı döndürür.

Tohumlama (seed): Bu seçenek ile üretilen rastgele sayılar, düğümler arasındaki bağlantıların başlangıç ağırlıklarını ayarlamak ve eğitim verilerini karıştırmak için kullanılmaktadır.

Eğitim Tekrarı (trainingTime): Eğitim için uygulanacak döngü sayısını ifade etmektedir. Doğrulama kümesi sıfırdan farklıysa, ağı erkenden bitirebilmektedir.

Doğrulama Kümesi Boyutu (validationSetSize): Doğrulama kümesi boyutunun yüzdesini ifade etmektedir. Eğitim, doğrulama kümesindeki hatanın giderek daha da kötüye gittiğini ve ya eğitim süresine ulaşıldığını gözlemleyinceye kadar devam edecektir.

Doğrulama Eşiği (validationThreshold): Doğrulama testini bitirmek amacıyla kullanılmaktadır. Buradaki değer, eğitim sonlandırılmadan önce doğrulama kümesi hatasının kaç kez daha kötüleşebileceğini belirtmektedir.

Katmanlı Çapraz Doğrulama (k- fold Cross Validation): Bu parametre ile sisteme yüklenen veriler k-sayısı kadar veri kümesine ayrılır. Veri kümeleri içerisinde biri test verisi olarak kullanılırken, diğerleri eğitim verisi olarak kullanılır ve bu işlem tüm veri kümeleri test kümesi olana kadar uygulanır. Başarı tüm gruplar için ortalama alınarak bulunur. Örneğin 100 verisi olan bir sistemde çapraz doğrulama sayısı 10 kat (fold) için yapılırsa, veriler eşit boyutta 10'arlı veri kümelerine bölünür, 10 veri test için 90 veri eğitim için ayrılır. Sonrasında diğer 10'lu veri kümesi, test verisi ve kalan 90 veri eğitim verisi olarak seçilir. Bütün veriler sırayla işlendikten sonra başarının hesaplanması için bütün setlerden elde edilen başarının ortalaması alınır. Bu sayede veriler doğrulanmış ve ağı eğitilmiş olur. Burada veri sayısına uygun olarak k-sayısı belirlenmelidir.

WEKA'nın sahip olduğu fonksiyon ise; özellik seçimidir (feature selection). Bu özellik ile sınıflar arası en önemli, parametreleri çeşitli fonksiyonlar vasıtasıyla belirlenerek kullanıcıya sunulur. Bu sayede kullanılması gereken özellik sayısı azaltılabilir ve doğruluk miktarı artırılabilir. Çünkü birbirine çok yakın değerlere sahip olan veriler hatalı değerlendirmelere sebep olabilmektedir. Geliştirilen sistemdeki 176 özelliğin aynı maddeyi tanımak için kullanılmasını gerektirmesi, maddenin tüm spektral bölgeyi tanımlayacak kadar zengin bir yapıda hem absorpsiyonun hem de reflektansının ayırt edici olmasını gerektirmektedir. Fakat böyle bir durumun meydana gelmesi oldukça zor bir durumdur. Yapay sinir ağı, maddenin tanımlanmasında kullanılamayacak özellikleri giriş ağırlıkları ile elimine etse de bu özelliklerin bozucu etkisi görülebilmektedir. Bunun en büyük sebeplerinden birisi de aşırı uyum (over fitting) problemleridir. Aşırı

uyum problemlerinde sistem sonuçları ezberleyerek, sadece eğitiminde kullanılan sonuçlara cevap verebilecek yapıda oluşturulur. Bunun önlenmesi için sistemde bilgi kazancı (infoGain) değerlendiricisi adı verilen sınıfla ilgili bit bazında bilgi miktarını ölçerek bir özellik değerini değerlendiren değerlendiricinin ranker arama metodu kullanılmıştır. Bilgi kazancı özellik seçimi ile seçilen özellikler ranker arama metodu ile bir sınıfa ait verileri, diğer sınıfa ait verilerden en uzak olan özelliğe en yüksek puanı vererek en yüksekten en düşüğe doğru sıralar. Birbirine en çok yaklaşmış hatta birbirinin içerisine girmiş olan veriler en düşük değeri alır. En yüksek rank değerine sahip olan değerlerden başlanılarak, özelliklerin sayısı, ideal hata oranına ulaşılan kadar artırılabilir. Böylece maddenin tanımlanması için tüm özelliklerin kullanılmadığı sistemler elde edilerek, daha az maliyetli, daha hızlı ve probleme yönelik sistemler elde edilebilmektedir.

3. BÖLÜM

LED'Lİ FOTOMETRİK ÖLÇÜM SİSTEMİ DENEYLERİ

Tasarımı gerçekleştirilen sistem üzerinden alınan verilerin değerlendirilmesi için süt, su ve etil alkol numuneleri üzerinde denemeler yapılmıştır. Sistem testi için sütün seçilmesinin en önemli sebepleri; sütün yapısında ihtiva ettiği organik ve inorganik bileşenleri ile çeşitlilik açısından zengin maddelerin olması, üzerinde bakteri ve mantar gibi mikroskobik canlıların üreyebilmesidir. Suyun test numunesi olarak seçilmesinde ise; içerisinde neredeyse hiçbir organik bileşen bulunmaması, daha çok inorganik mineral içermesi ve süte göre içerdiği madde bakımından daha fakir olmasından dolayı sınıflandırmasının mevcut sistem ile zor olacağının düşünülmesidir. Etil alkol ise şeffaf yapısı ile su ile görsel metotlar ile ayıramaması, içerisinde mineral değil, organik bileşen olan alkol ihtiva etmesi sebebiyle seçilmiştir.


3.1. Süt Üzerinde Yapılan Deneyler

Gerçekleşen sistemimiz ile organik bileşen denemeleri yapmak amacıyla süt üzerinde deneysel ölçümler alınmıştır. On altı farklı üreticiden alınan sütlerin ayrımı konusunda tasarlanan sistemin başarısı test edilmiştir. Yağ, karbonhidrat, protein gibi zengin organik maddelerin yanı sıra su, kalsiyum, fosfor gibi inorganik maddeler içermektedir. Sütün içerisindeki bu oranların canlıdan canlıya, günden güne miktarının değişebildiği bilinmektedir. Bunun yanında sütün tazeliğini kaybedebilmesi, bozulabilmesi, insanlara brusella gibi bazı hastalıkları bulaştırabilecek yapısının olması; tespitinin hızlı, güvenilir ve maliyeti düşük bir şekilde yapılmasını gerektirmektedir. Bu sebeplerden dolayı sütün örnek olarak seçilmesi, insan sağlığı açısından oldukça önemli bir rol oynamaktadır. Bu nedenlerle süt üzerinde 2 farklı deney yapılmıştır. Bunlar sütün markasına göre sınıflandırılması ve sütün bekleme süresine göre sınıflandırılmasıdır. Sütün markasına göre sınıflandırılması ile sütün ihtiva ettiği maddelerin zenginliğine göre

sınıflandırılması hedeflenmiş olup sütun kalite tespitinde kullanılabilirliği sorgulanmıştır. Sütun bekleme süresine göre sınıflandırılması ile süt içerisinde üreyebilecek mikroorganizma miktarındaki değişime göre sütun beklediğinde kaybettiği tazeliğine göre sınıflandırılması hedeflenmiştir.

3.1.1. Sütün Markasına Göre Sınıflandırılması

Verinin işlenebilmesi için gerekli ölçümler 16 marka için alınmış olup her numune en az 25'er kez ölçülerek toplamda 400 veri elde edilmiştir. Her ölçüm 22 LED için parametrik reflektans ve absorbans ölçümleri alınarak her ışık dijital dönüştürücüsünden kızılötesi, görülür, tam bantta ve lüks biriminde olmak üzere toplamda 176 özellik çıkarılmıştır. Bu sayede 400 satır, 177 sütunluk (özelliklere ek olarak, bir sütun da sınıfını belirtmek için kullanılmıştır) matris elde edilmiştir. WEKA üzerinde alınan verilerin örnek gösterimi Şekil 3.1'de verilmektedir.



Şekil 3.1. WEKA Üzerinde Verilerin Dağılımının Görülmesi

Sistemde alınan veriler; öncelikle ağı eğitilip eğitilemediğinin kontrolünün sağlanması ve yapay sinir ağının başarısını görmek açısından çapraz doğrulama (cross validation) kullanılmıştır. Yapay Sinir Ağı Tablo 3.1'deki özelliklere göre eğitilmiştir.

Tablo 3.1. Yapay Sinir Ağı Eğitim Parametreleri

Parametre Adı	Seçim
Otomatik Yapılandırma (auto build)	Aktif
batchSize	100
doNotCheckCapabilities	Pasif
hiddenLayers	a
learningRate	0.3
momentum	0.2
nominalToBinaryFilter	Aktif
normalizeAttributes	Aktif
numDecimalPlaces	2
reset	Aktif
seed	0
trainingTime	500
validationSetSize	0
validationThreshold	20
Ayrım için kullanılan parametre sayısı	176
Cross Validation Folds	10

Verilen parametreler doğrultusunda markasına göre sütün analizi WEKA üzerinde çapraz doğrulama ile gerçekleştirilmiş ve elde edilen sonuçlar Şekil 3.2.'de gösterilmiştir.

	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	
23	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	a
1	23	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	b
0	0	25	0	0	0	0	0	0	0	0	0	0	0	0	0	0	c
0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	0	0	d
0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	0	e
0	0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	0	f
0	0	0	0	0	0	25	0	0	0	0	0	0	0	0	0	0	g
1	0	0	0	1	0	0	23	0	0	0	0	0	0	0	0	0	h
0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	0	0	i
0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	0	j
0	0	0	0	0	0	0	0	0	0	25	0	0	0	0	0	0	k
2	2	0	0	0	0	0	0	0	0	0	21	0	0	0	0	0	l
0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	0	m
0	0	0	0	0	0	0	0	0	0	0	0	1	0	24	0	0	n
0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	o
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	p

Şekil 3.2. Markasına Göre Süt Verisinin Karışıklık Matrisi (Çapraz Doğrulama).

Bu örnekler arasından (f) organik süt; (g), (i) ve (m) light süt; (n) günlük süt, (o) laktozsuz süt, diğer sütler ise yağlı inek sütüdür.

Veriler incelendiğinde, karışma büyük ölçüde kendi grubu arasında oluşmuş olup sadece günlük süt verisi olan (n) sütündeki ölçümlerden birisi (l) sütü ile karıştırılmıştır. Bu da sütün yağlı süt, light süt, günlük süt ya da laktozsuz süt olarak yüksek doğrulukta ayrımının gerçekleştirilebildiğini göstermektedir. Sistemin genel olarak üreticisine göre ayırma başarısı yüzde 97.25 olarak hesaplanmıştır. Sistemdeki veriler incelenecek olursa (a) marka sütten alınan 25 ölçümün 23'ü doğru olarak bilinmiş, bir ölçüm (b) verisi ile bir ölçüm (l) verisi ile karıştırılmıştır. Karıştırılan tüm sütler yağlı süt arasında gerçekleştirilmiştir. Benzer şekilde 25 adet (b) sütüne ait ölçümün 23'ü doğru bilinmiş, bir adet ölçüm (a) verisi ile, bir adet ölçüm (l) verisi ile karıştırılmıştır. (l) sütüne ait verilerden 2 tanesi (a) ölçümleriyle 2 tanesi de (b) ölçümleriyle karıştırılmış, 21 veri doğru olarak bilinmiştir.

Bir süt ölçümü için 176 parametre kullanılması, sistem performansı ve hesaplama süresi açısından olumsuz etkilere sahiptir. Sistem genel olarak 365nm ile 950nm arası spektrum bölgesini kapsayacak şekilde tasarlanmış olup, süt ölçümü için belli parametrelerin kullanılması sistemin hem ölçüm doğruluğu açısından, hem de ağırlık oluşturulması açısından önemlidir. Bunun için özellik seçimi (feature selection) yapılması ve sınıfları en iyi ayırt eden parametrenin bulunması gereklidir. Sınıflar arası ortalama uzaklık en fazla olan parametrelere göre değerlendirme yapılması sistemi hızlandırdığı gibi sistemin doğruluğu artırılabilir.

3.1.2. Markaya Göre Süt Verileri Üzerinde Ranker Metodu ile Özellik Seçimi

Ranker kendi özellik değiştiricisi (ReliefF, GainRatio, Entropy gibi) ile kullanılabilen, sınıf ayrımını en iyi yapan özelliğin en yüksek, en düşük yapanın ise en düşük puanı aldığı arama metodudur.

Info gain değerlendiricisinin Ranker arama metodu kullanılarak en iyi sonucu üreten parametre 12 numaralı LED'in görünür bölgedeki absorbansı olarak belirlenmiş olup, değeri 3.64385 olarak algoritma tarafından hesaplanmıştır. En kötü sonucu üreten parametrelerin değeri ise sıfır olup; 18 numaralı LED'in lux absorbans değeri, 3 numaralı LED'in lux reflektans değeri, 19 numaralı LED'in kızılötesi absorbans değeri, 18 numaralı LED'in kızılötesi absorbans değeri, 3 numaralı LED'in lux absorbans değeri, 19 numaralı LED'in absorbans lux değeri, 19 numaralı LED'in reflektans

kızılötesi değerleri olmuştur. 176 özellik içerisinde yüzde 10'luk kısmı olan 18 LED parametreleri Tablo 3.2.'de verilmiştir.

Tablo 3.2. Markasına Göre Süt Verisinin InfoGain Değerlendiricisinin Ranker Metodu ile En İyi 18 Parametresi

Ranker Değeri	Özellik
3.64385	56 AbsorbanceVisible_Led12
3.63135	34 AbsorbanceFull_Led12
3.52939	33 AbsorbanceFull_Led11
3.51606	78 AbsorbanceLux_Led12
3.51438	55 AbsorbanceVisible_Led11
3.48168	32 AbsorbanceFull_Led10
3.47256	54 AbsorbanceVisible_Led10
3.45713	28 AbsorbanceFull_Led6
3.42822	58 AbsorbanceVisible_Led14
3.41769	50 AbsorbanceVisible_Led6
3.41253	57 AbsorbanceVisible_Led13
3.40916	37 AbsorbanceFull_Led15
3.40508	35 AbsorbanceFull_Led13
3.3788	77 AbsorbanceLux_Led11
3.3763	12 AbsorbanceIR_Led12
3.3688	6 AbsorbanceIR_Led6
3.35407	36 AbsorbanceFull_Led14
3.35216	59 AbsorbanceVisible_Led15

Tablo 3.3. Markasına Göre Süt Verisinin Ranker Metodu ile Seçilen En İyi 18 Özelliğinin Sistem Başarısı Üzerine Etkileri

En iyi 1 parametre	287 doğru sınıflandırma %71.25 başarı
En iyi 2 parametre	288 doğru sınıflandırma %72 başarı
En iyi 3 parametre	289 doğru sınıflandırma %72.25 başarı
En iyi 4 parametre	283 doğru sınıflandırma %70.75 başarı
En iyi 5 parametre	290 doğru sınıflandırma %72.5 başarı
En iyi 6 parametre	306 doğru sınıflandırma %76.5 başarı
En iyi 7 parametre	311 doğru sınıflandırma %77.75 başarı
En iyi 8 parametre	385 doğru sınıflandırma %96.25 başarı
En iyi 9 parametre	392 doğru sınıflandırma %98 başarı
En iyi 10 parametre	392 doğru sınıflandırma %98 başarı
En iyi 11 parametre	393 doğru sınıflandırma %98.25 başarı
En iyi 12 parametre	396 doğru sınıflandırma %99 başarı
En iyi 13 parametre	395 doğru sınıflandırma %98.75 başarı
En iyi 14 parametre	393 doğru sınıflandırma %98.25 başarı
En iyi 15 parametre	395 doğru sınıflandırma %98.75 başarı
En iyi 16 parametre	396 doğru sınıflandırma %99 başarı
En iyi 17 parametre	396 doğru sınıflandırma %99 başarı
En iyi 18 parametre	395 doğru sınıflandırma %98.75 başarı

Bu sonuçlar için yapay sinir ağı eğitilerek Tablo 3.3'deki sonuçlar elde edilmiştir. Sonuçlar 400 veri üzerinden değerlendirilmiştir. Görüldüğü üzere ilk 12 parametre kullanımıyla birlikte başarı oranı %99'a kadar çıkarılmıştır. İlk 12 parametre için 6, 10, 11, 12, 13, 14 ve 15'inci LED'ler ve bu LED'lere ait sadece parametrik absorbans değerleri kullanılmıştır. Bu sayede daha kısa işlem süresi, daha az maliyet ve daha yüksek başarı yüzdesi ile sütün sınıflandırılabilmesi mümkün hale gelmiştir. Tüm LED'ler kullanıldığında yaklaşık 10 dakika kadar süren ağın oluşturulması işlemi, bir dakikadan kısa sürede oluşturulabilmiş ve rastgele ölçüm sonuçları sistem üzerinde değerlendirilmiştir.

3.1.3. Markaya Göre Süt Verisi Üzerinde Test Verisi Kullanımı

Sistem üzerinde öncelikle 70 adet numune ölçümleri üzerinden alınan veriler 176 parametre için test edilmiştir. Burada verilen test ölçümleri ağın eğitilmesinde kullanılan verilerden farklı olarak verilmiş olup, ağın eğitim verilerini ezberleme yoluna gidip gitmediğinin kontrolünü gerçekleştirmek amacıyla verilmiştir. Verilen 70 veri, 7 farklı süt markasının ürünü olup (d), (f), (i), (m), (n), (o) ve (p) marka sütlerden meydana gelmektedir. Şekil 3.3'te test işlemi için hesaplanan karışıklık matrisi görülmektedir.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	b
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	c
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	d
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	e
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	f
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	g
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	h
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	k
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	l
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	o
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	p
0	0	0	10	0	10	0	0	0	0	0	0	20	10	10	10	0	q = Test

Şekil 3.3. Markasına Göre Süt Verisinin Karışıklık Matrisi (Test Verisi ile Analiz)

Sonuçlar incelendiğinde sadece; (i) marka yarım yağlı sütün yine yarım yağlı olan (m) marka süt ile karıştığı, bunun dışındaki tüm verilerin doğru olarak sınıflandırıldığı görülmüştür. Özellik seçimi için en iyi 12 parametre kullanıldığında da sonucun değişmediği gözlemlenmiştir.

Yapılan ikinci testte ise; aynı marka ve aynı tipte olup farklı seri numaralara ve farklı son kullanım tarihine sahip sütler karşılaştırılmıştır. Bu çalışma ile amaç sütün paketten pakete değişebilir yapısının olduğunu gözlemlemektir. Bunun sebebi, sütler tek bir hayvan ya da tek bir üretici tarafından alınmayıp genellikle belirli aralıklarla satıcı tarafından toplanılan ve fabrikada işlenen bir tüketim maddesidir. Sütler, tek bir hayvandan alınmış olsa dahi sütün içerisindeki su, protein, karbonhidrat, mineral ve yağ gibi içerdiği maddeler hayvanın beslenmesine bağlı olarak farklılıklar gösterebilmektedir. Ayrıca süt, homojen bir yapıda görünmesine rağmen beklediği takdirde ayrılarak süt içerisindeki yağ sütün üzerine çıkmaktadır.

Markasına göre yapılan analizde tüm özellikler kullanılarak işlem gerçekleştirildiğinde Şekil 3.4'deki sonuçlar elde edilmiştir.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q		
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		a
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		b
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		c
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		d
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		e
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		f
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		g
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		h
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		i
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		j
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		k
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		l
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		m
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		n
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		o
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		p
0	0	0	14	0	0	0	21	0	0	0	1	0	0	0	0	0		q = Test

Şekil 3.4. Markasına Göre Süt Verisinin Karışıklık Matrisi (176 Özellik İçin Test)

Oluşturulan test verisi içerisinde 14 adet aynı numuneden alınan, ağı daha önce görmediği ölçümler ile, yine aynı markanın, aynı özellikteki (tam yağlı) farklı seri

numarasına sahip sütünden alınan 22 veriden oluşmaktadır. Sistem üzerinde farklı paketten alınan sütün farklı kategoriye yerleşmesinin sebebi üreticilerin sütü farklı çiftliklerden farklı miktarlarda alıyor olmasından kaynaklanmakta olup, verinin çok fazla saçılmadan yerleştirilmesi başarı kriteri olarak görülmektedir. Farklı seri numarasına sahip olan süt ile (h) sütü birbirine oldukça yakın sütler olup ikisi de tam yağlı süt kategorisindedir.

Aynı test kümesi InfoGain değerlendiricisinin Ranker metodunda %99 doğrulukla tespit edilen en iyi 12 ölçüm parametresi kullanılarak elde edilen ağ üzerinde test edilmiştir. Elde edilen WEKA sistem çıktısı Şekil 3.5'te gösterilmiştir.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	b
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	c
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	d
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	e
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	f
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	g
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	h
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	i
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	j
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	k
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	l
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	m
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	o
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	p
0	0	0	14	0	0	0	0	0	22	0	0	0	0	0	0	0	q = Test

Şekil 3.5. Markasına Göre Süt Verisinin Karışıklık Matrisi (Seçilen 12 Özellik İçin Test)

Test sonucunda; saçılmanın tamamen giderilebildiği görülmektedir. Daha önce tahminlerde bir ölçüm verisi yapay sinir ağı tarafından (l) marka süt olarak değerlendirilen sonuç (j) marka olacak şekilde düzelmiştir.

Genel olarak sistem çalışması incelendiğinde; tespit edilen 12 özellik sütün sınıflandırılabilmesi açısından yeterli ve daha doğru sonuçlar üretebilmiş olduğu sonucuna ulaşılmıştır. Sistemde bulunan ayırım için kullanılamayan parametreler sistemde bozucu etkiye sebep olarak başarıyı düşürebilmekte ve işlem süresini de uzatmakta olduğu gözlemlenmiştir. Yapak sinir ağı için verilen veriler genel olarak

tutarlılık göstermiştir, bu da yapay sinir ağı için verilen eğitim kümesinin yeterli olduğunu, sistemin eğitim verisini ezberlemeden sınıflandırma yapabildiğini göstermiştir.

3.1.4. Sütün Bekleme Süresine Göre Sınıflandırılması

Süt bekledikçe besin değerini kaybeden ve insan sağlığını olumsuz yönde etkileyebilecek bakteri üremesine müsait bir tüketim maddesidir. Sistemde bakteri yoğunluğunu gözlemlemek amacıyla 25 derecede bekletilmiş süt, 7 gün boyunca ağız kapalı olarak bekletilmiştir. Sistemden ölçümler alındıktan sonra bu veriler WEKA üzerinde yapay sinir ağı üzerinde sınıflandırmaya tabi tutulmuştur. Yapay sinir ağı parametreleri daha önceki markasına göre sınıflandırmada kullanılan parametreler ile aynı seçilmiştir. Her bir gün için 20 ölçüm alınmış, toplam 160 ölçüm için yapay sinir ağının karışıklık matrisi Şekil 3.6’de verilmiştir.

a	b	c	d	e	f	g	h	
19	1	0	0	0	0	0	0	a = ilkGun
0	20	0	0	0	0	0	0	b = birinciGun
0	0	19	0	1	0	0	0	c = ikinciGun
0	0	0	20	0	0	0	0	d = ucuncuGun
0	0	0	1	19	0	0	0	e = dorduncuGun
0	0	0	0	0	20	0	0	f = besinciGun
0	1	0	0	0	0	19	0	g = altinciGun
0	0	0	0	0	0	0	20	h = yedinciGun

Şekil 3.6. Bekleme Süresine Göre Sütün Karışıklık Matrisi (Çapraz Doğrulama)

Ağın başarısı incelendiğinde; bir adet ilk gün ölçümü (beklememiş ölçüm) 1. gün ölçümü ile bir adet 2. Gün ölçümü dördüncü gün ile bir adet 4. gün ölçümünü üçüncü gün ölçümü ile, bir adet altıncı gün ölçümü 1. gün ölçümü ile karışmıştır. Sistemin başarısı 176 özellik için %97.5’da kalmıştır.

3.1.5. Sütün Bekleme Süresi Verileri Üzerinde Ranker Metodu ile Özellik Seçimi

Sistemin başarısını artırabilmek için infoGain Ranker metodu ile özellik seçimi yapılmıştır. Ranker metodunda görülen en iyi 18 parametre Tablo 3.4’te verilmiştir. Sistemin ilk sütununda ranker metodunun ilgili satırında bulunan özellik için belirlemiş olduğu puan görülmektedir.

Tablo 3.4. Bekleme Süresine Göre Süt Verisinin InfoGain Değerlendiricisinin Ranker Metodu ile En İyi 18 Özelliği

Ranker Değeri	Özellik
2.6805	45 AbsorbanceVisible_Led1
2.6198	23 AbsorbanceFull_Led1
2.6094	21 AbsorbanceIR_Led21
2.6082	1 AbsorbanceIR_Led1
2.5559	50 AbsorbanceVisible_Led6
2.5509	65 AbsorbanceVisible_Led21
2.5351	28 AbsorbanceFull_Led6
2.5276	20 AbsorbanceIR_Led20
2.5252	43 AbsorbanceFull_Led21
2.5207	4 AbsorbanceIR_Led4
2.5186	49 AbsorbanceVisible_Led5
2.5146	32 AbsorbanceFull_Led10
2.5075	27 AbsorbanceFull_Led5
2.4904	54 AbsorbanceVisible_Led10
2.4851	42 AbsorbanceFull_Led20
2.4851	64 AbsorbanceVisible_Led20
2.4781	29 AbsorbanceFull_Led7
2.4577	24 AbsorbanceFull_Led2

Bu sonuçlar için özellik seçimi yapılarak ağ eğitilmiştir. Eğitime ait veriler Tablo 3.5.'te verilmiştir.

Tablo 3.5. Bekleme Süresine Göre Süt Verisinin Ranker Metodu ile Seçilen En İyi 18 Özelliğinin Sistem Başarısı Üzerine Etkileri

En iyi 1 parametre	124 doğru sınıflandırma %77.5 başarı
En iyi 2 parametre	127 doğru sınıflandırma %79.375 başarı
En iyi 3 parametre	146 doğru sınıflandırma %91.25 başarı
En iyi 4 parametre	143 doğru sınıflandırma %89.375 başarı
En iyi 5 parametre	153 doğru sınıflandırma %95.625 başarı
En iyi 6 parametre	155 doğru sınıflandırma %96.875 başarı
En iyi 7 parametre	154 doğru sınıflandırma %96.25 başarı
En iyi 8 parametre	155 doğru sınıflandırma %96.875 başarı
En iyi 9 parametre	152 doğru sınıflandırma %95 başarı
En iyi 10 parametre	154 doğru sınıflandırma %96.25 başarı
En iyi 11 parametre	154 doğru sınıflandırma %96.25 başarı
En iyi 12 parametre	156 doğru sınıflandırma %97.5 başarı
En iyi 13 parametre	155 doğru sınıflandırma %96.875 başarı
En iyi 14 parametre	156 doğru sınıflandırma %97.5 başarı
En iyi 15 parametre	156 doğru sınıflandırma %97.5 başarı
En iyi 16 parametre	156 doğru sınıflandırma %97.5 başarı
En iyi 17 parametre	154 doğru sınıflandırma %96.25 başarı
En iyi 18 parametre	152 doğru sınıflandırma %95 başarı

176 özellik ile sağlanan başarı en iyi 12 özelliğin seçilerek kullanılması ile sağlanmıştır ancak başarıyı artırıcı bir etkisi yakalanamamıştır. Başarıyı artırmak adına öğrenme oranı, momentum, eğitim tekrarı, çapraz doğrulama gibi parametreler ağına iyileştirilmesi için değiştirilmiş olsa da başarının artırılması sağlanamamıştır. 12 özellik seçilerek kullanıldığında yapay sinir ağı daha kısa sürede oluşturulabilmektedir.

3.1.6. Bekleme Süresine Göre Süt Verisi Üzerinde Test Verisi Kullanımı

Eğitilmiş olan ağı test edilmesi için ağı daha önce görmediği veriler yapay sinir ağına uygulanmış ve verilerin hangi sınıfa yerleştirileceğini görmek adına test verileri uygulanmıştır. Test verisi 2 adet ilk gün alınmış olan numuneden, 5 adet bir gün beklemiş sütten, 5 adet 3 gün beklemiş sütten ve 5 adet farklı markadan alınmış ilk gün verisinden meydana gelmektedir. Sistem başka markadan alınan süt için eğitilmemiş ve ilk önce en iyi 12 özellik üzerinde test işlemi sağlanmıştır. WEKA üzerinden alınan karışıklık matrisi Şekil 3.7’de, test sonuçları Tablo 3.6’da, gösterilmiştir.

a	b	c	d	e	f	g	h	i	<-- classified as
1	1	0	0	0	0	0	0	0	a = ilkGun
1	4	0	0	0	0	0	0	0	b = birinciGun
0	0	0	0	0	0	0	0	0	c = ikinciGun
0	0	0	5	0	0	0	0	0	d = ucuncuGun
0	0	0	0	0	0	0	0	0	e = dorduncuGun
0	0	0	0	0	0	0	0	0	f = besinciGun
0	0	0	0	0	0	0	0	0	g = altinciGun
0	0	0	0	0	0	0	0	0	h = yedinciGun
0	0	0	0	5	0	0	0	0	i = Test

Şekil 3.7. Bekleme Süresine Göre Sütün Karışıklık Matrisi (Seçilen 12 Özellik İçin Test).

Alınan bu sonuçlara göre 2 adet ilk gün verisi arasından 1’i doğru tahmin edilirken diğeri 1 gün beklemiş olan süt ile karıştırılmış, 5 adet bir gün beklemiş süt ölçümü arasından 1’i ilk gün verisi ile karıştırılmış, üçüncü gün verisi tamamen doğru sınıflandırılmış ve farklı marka olan süt ise tamamen hatalı olarak sınıflandırılmıştır.

Tablo 3.6.Seçilen 12 Özellik İçin Bekleme Süresine Göre Süt Verisi Üzerinde Hata Tablosu

Numune No	Gerçekte Olan	Tahmin Edilen	Hata	Tahmin Oranı
1	1:ilkGun	2:birinciGun	+	0.973
2	1:ilkGun	1:ilkGun		0.98
3	2:birinciGun	1:ilkGun	+	0.909
4	2:birinciGun	2:birinciGun		0.693
5	2:birinciGun	2:birinciGun		0.92
6	2:birinciGun	2:birinciGun		0.471
7	2:birinciGun	2:birinciGun		0.556
8	4:ucuncuGun	4:ucuncuGun		0.586
9	4:ucuncuGun	4:ucuncuGun		0.669
10	4:ucuncuGun	4:ucuncuGun		0.686
11	4:ucuncuGun	4:ucuncuGun		0.789
12	4:ucuncuGun	4:ucuncuGun		0.744
13	9:Test	5:dorduncuGun	+	0.992
14	9:Test	5:dorduncuGun	+	0.992
15	9:Test	5:dorduncuGun	+	0.992
16	9:Test	5:dorduncuGun	+	0.992
17	9:Test	5:dorduncuGun	+	0.992

Sistemin 176 özellik için çalışması da incelenmiş ve başarısının daha yüksek olduğu görülmüştür. Aynı test verileri ile alınan sonuçlar Tablo 3.7’de test sonuçları ve Şekil 3.8.’deki karışıklık matrisinde gösterilmiştir.

a	b	c	d	e	f	g	h	i	<-- classified as
1	1	0	0	0	0	0	0	0	a = ilkGun
0	5	0	0	0	0	0	0	0	b = birinciGun
0	0	0	0	0	0	0	0	0	c = ikinciGun
0	0	0	4	1	0	0	0	0	d = ucuncuGun
0	0	0	0	0	0	0	0	0	e = dorduncuGun
0	0	0	0	0	0	0	0	0	f = besinciGun
0	0	0	0	0	0	0	0	0	g = altinciGun
0	0	0	0	0	0	0	0	0	h = yedinciGun
0	1	0	0	4	0	0	0	0	i = Test

Şekil 3.8. Bekleme Süresine Göre Sütün Karışıklık Matrisi (176 Özellik İçin Test)

176 özellik için veriler incelendiğinde; sütün ilk günkü ölçümü ile birinci gündeki ölçümünün halen karıştırıldığı, ikinci günden alınan sütün tamamının doğru bilindiği, üçüncü gündeki sütten bir ölçümün dördüncü gün ile karıştırıldığı görülmüştür, ancak test için verilen farklı marka sütün bir ölçümünün sonuca yakınsadığı görülmüştür. Yapay sinir ağının eğitimi için farklı markaların bekleme sürelerinin sisteme veri olarak

girilmesi ve daha uygun özelliklerin seçilmesi ile mevcut başarı miktarı artırılabilir.

Tablo 3.7. Seçilen 176 Özellik İçin Bekleme Süresine Göre Süt Verisi Üzerinde Test Verisi Hata Tablosu

Numune No	Gerçekte Olan	Tahmin Edilen	Hata	Tahmin Oranı
1	1:ilkGun	2:birinciGun	+	0.891
2	1:ilkGun	1:ilkGun		0.994
3	2:birinciGun	2:birinciGun		0.979
4	2:birinciGun	2:birinciGun		0.986
5	2:birinciGun	2:birinciGun		0.984
6	2:birinciGun	2:birinciGun		0.982
7	2:birinciGun	2:birinciGun		0.984
8	4:ucuncuGun	4:ucuncuGun		0.982
9	4:ucuncuGun	4:ucuncuGun		0.979
10	4:ucuncuGun	5:dorduncuGun	+	0.911
11	4:ucuncuGun	4:ucuncuGun		0.984
12	4:ucuncuGun	4:ucuncuGun		0.985
13	9:Test	5:dorduncuGun	+	0.901
14	9:Test	2:birinciGun	+	0.822
15	9:Test	5:dorduncuGun	+	0.859
16	9:Test	5:dorduncuGun	+	0.912
17	9:Test	5:dorduncuGun	+	0.949

3.2. Su ve Etil Alkol Üzerinde Yapılan Deneyler

Sistemde farklı kaynaklardan alınan su verileri incelenerek sistem üzerinde deneyler gerçekleştirilmiştir. Sisteme sonradan %96 saflıkta etil alkol verisi eklenerek sistem tekrar denenmiştir. Buradaki amaç öncelikle molekül yapısı çok küçük maddelerin tespitinin gerçekleştirilmesidir. Etil alkol ile birlikte daha büyük yapıdaki organik moleküllerin sistem tarafından algılanıp algılanmadığını öğrenmek amacıyla testler yapılmıştır.

3.2.1. Kaynağına Göre Su Üzerinde Yapılan Deneyler

Sistem üzerinde 9 farklı kaynağa ait sular üzerinden alınan veriler ile yapay sinir ağı eğitilmiştir. Öncelikle sistem 176 veri için eğitilmiştir. Eğitim için toplamda 180 ölçüm kullanılmıştır ve eğitilen ağ ile %100 başarı elde edilmiştir. Yapay sinir ağının eğitilmesi sonucunda alınan karışıklık matrisi Şekil 3.9.'te verilmiştir.

a	b	c	d	e	f	g	h	i	<-- classified as
20	0	0	0	0	0	0	0	0	a = Madran
0	20	0	0	0	0	0	0	0	b = Toros
0	0	20	0	0	0	0	0	0	c = Koycegiz
0	0	0	20	0	0	0	0	0	d = GokceAgac
0	0	0	0	20	0	0	0	0	e = Camlica
0	0	0	0	0	20	0	0	0	f = DistileSu
0	0	0	0	0	0	20	0	0	g = Uludag
0	0	0	0	0	0	0	20	0	h = SekerPinari
0	0	0	0	0	0	0	0	20	i = KayseriSebekeSuyu

Şekil 3.9. Kaynağına Göre Su Karışıklık Matrisi (Çapraz Doğrulama)

Karışıklık matrisi incelendiğinde sistemin başarısının idealdeki seviyede olduğu görülmüş sistem hiçbir suyu bir diğeriyle karıştırılmamıştır.

3.2.2. Su Verileri Üzerinde Ranker Metodu ile Özellik Seçimi

Su verileri üzerinde ranker metodu kullanılarak özellik seçimi yapılmıştır. Yapılan seçim için 18 en iyi sonuç incelenmiştir. Ranker işlemi sonucu Tablo 3.8’de verilmiştir.

Ranker metodunda reflektans ölçümü suyun sınıflandırılmasında önemli rol oynamıştır. Suyun absorbansı ölçülebilecek en düşük absorbansı oluşturmaktadır. Hatta havaya göre düşünüldüğünde, ışık kanalı vazifesi görerek ışığı toplamakta olduğu bu sebeple de boş küvetten alınan verilere göre hesaplandığında absorbans parametresi bazında negatif değerlerin oluşmasına neden olmuştur. Negatif olması sistem performansı açısından bozucu bir etkisinin olmadığı alınan sonuçlarda görülmüştür. Yapay sinir ağı negatif girişleri tanıyabildiği görülmüştür. Ranker metodundan alınan verilere göre sistemin başarısı Tablo 3.9’da verilmiştir.

Yapılan analizlerde ölçülen veriler için %100 doğruluk sağlanmıştır. En iyi 9 sonuç kullanıldığında 176 özellikte yakalanılan başarı yakalanabilmektedir. Ayrımının süte göre daha zor olacağı düşülmesine rağmen süt verilerinden çok daha iyi sonuçlar alınmıştır. Sonuçların daha iyi olmasının sebebi olarak suyun homojen yapısı olduğu düşünülmektedir. Sistemde herhangi bir ayraç madde kullanımı olmadan yapılan sınıflandırmada elde edilen keskin sonuçlar sayesinde ayraç maddeden tasarruf sağlanabilecektir. Sistemde ayraç madde kullanılırsa mineral bazlı ayrımlar daha kolay yapılabileceği gibi sistem sadece sınıflandırmanın ötesinde mineral miktarının ölçümünü alabilecektir.

Tablo 3.8. Kaynağına Göre Su Verisinin InfoGain Değerlendiricisinin Ranker Metodu ile En İyi 18 Özelliği

Ranker Değeri	Özellik
3.06632	11 AbsorbanceIR_Led11
3.06632	55 AbsorbanceVisible_Led11
3.02513	45 AbsorbanceVisible_Led1
2.99374	1 AbsorbanceIR_Led1
2.99374	23 AbsorbanceFull_Led1
2.99236	108 ReflectanceIR_Led20
2.96821	122 ReflectanceFull_Led12
2.96821	144 ReflectanceVisible_Led12
2.96036	152 ReflectanceVisible_Led20
2.95006	130 ReflectanceFull_Led20
2.94772	153 ReflectanceVisible_Led21
2.91548	148 ReflectanceVisible_Led16
2.91548	126 ReflectanceFull_Led16
2.90707	54 AbsorbanceVisible_Led10
2.8912	65 AbsorbanceVisible_Led21
2.8912	21 AbsorbanceIR_Led21
2.87353	154 ReflectanceVisible_Led22
2.87088	12 AbsorbanceIR_Led12

Tablo 3.9. Kaynağına Göre Su Verisinin Ranker Metodu ile Seçilen En İyi 18 Özelliğinin Sistem Başarısı Üzerine Etkileri

En iyi 1 parametre	133 doğru sınıflandırma % 73.8889 başarı
En iyi 2 parametre	138 doğru sınıflandırma % 76.6667 başarı
En iyi 3 parametre	151 doğru sınıflandırma % 83.8889 başarı
En iyi 4 parametre	146 doğru sınıflandırma % 81.1111 başarı
En iyi 5 parametre	150 doğru sınıflandırma % 83.3333 başarı
En iyi 6 parametre	179 doğru sınıflandırma % 99.4444 başarı
En iyi 7 parametre	177 doğru sınıflandırma % 98.3333 başarı
En iyi 8 parametre	178 doğru sınıflandırma % 98.8889 başarı
En iyi 9 parametre	180 doğru sınıflandırma % 100 başarı
En iyi 10 parametre	179 doğru sınıflandırma % 99.4444 başarı
En iyi 11 parametre	179 doğru sınıflandırma % 99.4444 başarı
En iyi 12 parametre	179 doğru sınıflandırma % 99.4444 başarı
En iyi 13 parametre	180 doğru sınıflandırma % 100 başarı
En iyi 14 parametre	179 doğru sınıflandırma % 99.4444 başarı
En iyi 15 parametre	180 doğru sınıflandırma %100 başarı
En iyi 16 parametre	178 doğru sınıflandırma %98.8889 başarı
En iyi 17 parametre	180 doğru sınıflandırma %100 başarı
En iyi 18 parametre	180 doğru sınıflandırma %100 başarı

3.2.3. Su Verileri Üzerinde Test Verisi Kullanımı

Verilen 180 su verisi ile eğitilen yapay sinir ağı üzerine sistemin daha önce görmediği aynı kaynaklardan toplam 40 su verisi verilmiştir. 176 özellik için öncelikle inceleme yapılmıştır. Karıştırılan veriler Tablo 3.10'da görülmektedir.

Tablo 3.10. 176 Özellik İçin Kaynağına Göre Su Verisi Üzerinde Test Verisi Hata Tablosu

Numune No	Gerçekte Olan	Tahmin Edilen	Hata	Tahmin Oranı
1	1:Madran	1:Madran		0.972
2	1:Madran	1:Madran		0.979
3	1:Madran	2:Toros	+	0.92
4	1:Madran	3:Koycegiz	+	0.802
5	1:Madran	1:Madran		0.98
6	2:Toros	2:Toros		0.924
7	2:Toros	2:Toros		0.997
8	2:Toros	2:Toros		0.994
9	3:Koycegiz	3:Koycegiz		0.859
10	3:Koycegiz	3:Koycegiz		0.877
11	3:Koycegiz	3:Koycegiz		0.77
12	3:Koycegiz	3:Koycegiz		0.937
13	3:Koycegiz	3:Koycegiz		0.929
14	4:GokceAgac	4:GokceAgac		0.984
15	4:GokceAgac	4:GokceAgac		0.984
16	4:GokceAgac	4:GokceAgac		0.983
17	4:GokceAgac	4:GokceAgac		0.983
18	4:GokceAgac	4:GokceAgac		0.984
19	5:Camlica	5:Camlica		0.881
20	5:Camlica	5:Camlica		0.939
21	5:Camlica	5:Camlica		0.956
22	5:Camlica	5:Camlica		0.956
23	5:Camlica	5:Camlica		0.972
24	6:DistileSu	6:DistileSu		0.985
25	6:DistileSu	6:DistileSu		0.985
26	7:Uludag	7:Uludag		0.985
27	7:Uludag	7:Uludag		0.976
28	7:Uludag	7:Uludag		0.976
29	7:Uludag	7:Uludag		0.976
30	7:Uludag	7:Uludag		0.977
31	8:SekerPinari	8:SekerPinari		0.983
32	8:SekerPinari	8:SekerPinari		0.987
33	8:SekerPinari	8:SekerPinari		0.984
34	8:SekerPinari	8:SekerPinari		0.985
35	8:SekerPinari	8:SekerPinari		0.982
36	9:KayseriSebeke	9:KayseriSebeke		0.982
37	9:KayseriSebeke	9:KayseriSebeke		0.978
38	9:KayseriSebeke	9:KayseriSebeke		0.973
39	9:KayseriSebeke	9:KayseriSebeke		0.977
40	9:KayseriSebeke	9:KayseriSebeke		0.975

Test sonucuna ait karıştırılma matrisi Şekil 3.10'de verilmiştir. Karıştırılma matrisi incelendiğinde sadece Madran kaynaklı suyun karıştığı diğer suların karışmadığı gözlemlenmiştir. Madran, Toros ve Köyceğiz kaynaklı sular ile karıştırılmış olsa da doğru sınıflandırılan Madran kaynaklı verilerinin sayısı karıştırılan verilerin sayısından fazladır. Sistemin test sonucunda başarı oranı %95 olarak belirlenmiştir.


a	b	c	d	e	f	g	h	i	<-- classified as
3	1	1	0	0	0	0	0	0	a = Madran
0	3	0	0	0	0	0	0	0	b = Toros
0	0	5	0	0	0	0	0	0	c = Koycegiz
0	0	0	5	0	0	0	0	0	d = GokceAgac
0	0	0	0	5	0	0	0	0	e = Camlica
0	0	0	0	0	2	0	0	0	f = DistileSu
0	0	0	0	0	0	5	0	0	g = Uludag
0	0	0	0	0	0	0	5	0	h = SekerPinari
0	0	0	0	0	0	0	0	5	i = KayseriSebeke

Şekil 3.10. Kaynağına Göre Su Karışıklık Matrisi (176 Özellik İçin Test)


Sistem Ranker metodu ile %100 doğruluk göstermiş olan en iyi 9, en iyi 13, en iyi 15, en iyi 17 ve en iyi 18 özellik ile test edilmiştir ancak sonuç değişmeyip %95 olarak kalmıştır. Gerçekleştirilen düzenek ile ayraç madde kullanmadan kaynağına göre su ayrımı için %95 doğruluk ile sınıflandırılmasını sağlayabilmek dikkate değer bir sonuçtur.

3.2.4. Su Verileri İle Birlikte Etil Alkolün Eğitilip Sınanması

Gerçekleştirilen sistem üzerinde %96 saflıkta tıbbi etil alkol ve su verileri kullanılarak çapraz doğrulama ile testi gerçekleştirilmiştir. Etil alkol yapısı gereği organik bir bileşiktir. Suyu göre molekül büyüklüğü, yaptığı bağ sayısı, içerdiği atom sayısı, molekül ağırlığı farklıdır. Ancak renksiz olduğu için su ile görsel olarak ayrımını yapabilmek çok zordur. Şekil 3.11'de etil alkole ait molekül yapısı, Şekil 3.12'de ise suya ait molekül yapısı görülmektedir. Şekil 3.13'de çapraz doğrulama ile su ve alkol karışıklık matrisi verilmiştir.



Şekil 3.11. Etil Alkol Molekülü [107].



Şekil 3.12. Su Molekülü [108].

a	b	c	d	e	f	g	h	i	j	<-- classified as
20	0	0	0	0	0	0	0	0	0	a = Madran
0	19	0	0	0	1	0	0	0	0	b = Toros
0	0	20	0	0	0	0	0	0	0	c = Koycegiz
0	0	0	20	0	0	0	0	0	0	d = GokceAgac
0	0	0	0	20	0	0	0	0	0	e = Camlica
0	0	0	0	0	20	0	0	0	0	f = DistileSu
0	0	0	0	0	0	20	0	0	0	g = Uludag
0	0	0	0	0	0	0	20	0	0	h = SekerPinari
0	0	0	0	0	0	0	0	20	0	i = KayseriSebeke
0	0	0	0	0	0	0	0	0	20	j = EtilAlkolYuzdeDoksanAlti

Şekil 3.13. Su ve Etil Alkol Karışıklık Matrisi (Çapraz Doğrulama)

3.2.5. Su ve Alkol Verileri Üzerinde Ranker Metodu ile Özellik Seçimi

Su ve etil alkol verileri üzerinde Ranker metodu kullanılarak özellik seçilimi yapılmış ve sistem çıktısı Tablo 3.11’de gösterilmiştir. Çıkan sonuçlara göre su verilerinde olduğu gibi reflektans verilerinin önemli olduğu görülmektedir. Sistemde en yüksek Rank değeri 3.22869 olarak belirlenmiş olup 11 numaralı LED’in görülür bölgedeki absorbansı ile yine 11 numaralı LED’in kızılötesi bölgedeki absorbans değerleridir. Ranker metodu sonucunda 21 adet özellik 0 değerini alarak etil alkol ile suyu birbirinden ayırt etmek için yetersiz kalmıştır.

Tablo 3.11. Su ve Etil Alkol Verilerinin Ranker Metodu ile Seçilen En İyi 18 Özelliği

Ranker Değeri	Özellik
3.22869	55 AbsorbanceVisible_Led11
3.22869	11 AbsorbanceIR_Led11
3.16212	108 ReflectanceIR_Led20
3.14038	122 ReflectanceFull_Led12
3.14038	144 ReflectanceVisible_Led12
3.13332	152 ReflectanceVisible_Led20
3.12405	130 ReflectanceFull_Led20
3.12194	153 ReflectanceVisible_Led21
3.09293	148 ReflectanceVisible_Led16
3.09293	126 ReflectanceFull_Led16
3.08536	54 AbsorbanceVisible_Led10
3.07107	21 AbsorbanceIR_Led21
3.07107	65 AbsorbanceVisible_Led21
3.06835	23 AbsorbanceFull_Led1
3.06188	1 AbsorbanceIR_Led1
3.05517	154 ReflectanceVisible_Led22
3.05097	45 AbsorbanceVisible_Led1
3.04412	32 AbsorbanceFull_Led10

Ranker sonuçlarının sistem üzerindeki başarısını göstermek için sistem çapraz doğrulama ile Ranker sonucunda sıralanmış parametreler test edilmiştir. Buna göre ilk 6 özelliğin kullanılması sistemin yeterli başarıyı yakalaması için yeterli olduğu görülmüştür. İlk 6 özelliğin sadece 2’si absorbansa ait özellikler iken, 4 özellik reflektans özelliklerine aittir. Tablo 3.12’de su ve etil alkol verilerine göre ranker metodu ile seçilen en iyi 18 özelliğinin sistem başarısı üzerine etkileri verilmiştir.

Tablo 3.12. Su ve Etil Alkol Verilerine Göre Ranker Metodu ile Seçilen En İyi 18 Özelliğinin Sistem Başarısı Üzerine Etkileri

En iyi 1 parametre	155 doğru sınıflandırma %77.5 başarı
En iyi 2 parametre	162 doğru sınıflandırma %81 başarı
En iyi 3 parametre	196 doğru sınıflandırma %98 başarı
En iyi 4 parametre	194 doğru sınıflandırma %97 başarı
En iyi 5 parametre	195 doğru sınıflandırma %97.5 başarı
En iyi 6 parametre	200 doğru sınıflandırma %100 başarı
En iyi 7 parametre	200 doğru sınıflandırma %100 başarı
En iyi 8 parametre	200 doğru sınıflandırma %100 başarı
En iyi 9 parametre	199 doğru sınıflandırma %99.5 başarı
En iyi 10 parametre	200 doğru sınıflandırma %100 başarı
En iyi 11 parametre	200 doğru sınıflandırma %100 başarı
En iyi 12 parametre	200 doğru sınıflandırma %100 başarı
En iyi 13 parametre	200 doğru sınıflandırma %100 başarı
En iyi 14 parametre	200 doğru sınıflandırma %100 başarı
En iyi 15 parametre	200 doğru sınıflandırma %100 başarı
En iyi 16 parametre	200 doğru sınıflandırma %100 başarı
En iyi 17 parametre	200 doğru sınıflandırma %100 başarı
En iyi 18 parametre	200 doğru sınıflandırma %100 başarı

3.2.6. Yapay Sinir Ağında Su ve Alkol Üzerinde Test İşlemleri

Yapay sinir ağı üzerinde sistemin daha önce görmediği veriler kullanılarak test işlemi gerçekleştirilmiştir. Test ilk önce 176 özellik için gerçekleştirilmiş, sonrasında da Ranker metodu ile en iyi sonucu üreten özellikler seçilerek test işlemi gerçekleştirilmiş ve sonuçları karşılaştırılmıştır.

Tüm özelliklerin kullanıldığı sonuçlara göre toplamda 2 veri diğer veriler ile karıştırılmıştır. Bunlar birisi Madran kaynaklı su verisi ile etil alkol verisi diğeri ise yine Madran kaynaklı su verisi ile Köyceğiz kaynaklı su verisidir. Sistemin başarı %95.5556 olarak belirlenmiştir. Test verisi üzerindeki hatalı veriler Tablo 3.13’de görülmektedir.

Özellik seçimi uygulanarak en iyi 6 parametre kullanıldığında ise sistemin başarı yüzdesi değişmemiştir. Daha öncesinde karıştırılmış olan Madran kaynaklı su, Çamlıca kaynaklı su ile, Toros kaynaklı su ise distile su ile karıştırılmıştır. Etil alkol özellik seçimi sonucunda su ile karıştırılmamıştır.

Tablo 3.13. 176 Özellik İçin Su ve Etil Alkol Verisi Üzerinde Test Verisi Hata Tablosu

Numune No	Gerçekte Olan	Tahmin Edilen	Hata	Tahmin Oranı
1	1:Madran	1:Madran		0.964
2	1:Madran	1:Madran		0.975
3	1:Madran	10:EtilAlkolYuzdeDoksanAlti	+	0.673
4	1:Madran	3:Koycegiz	+	0.653
5	1:Madran	1:Madran		0.972
6	2:Toros	2:Toros		0.989
7	2:Toros	2:Toros		1
8	2:Toros	2:Toros		0.997
9	3:Koycegiz	3:Koycegiz		0.929
10	3:Koycegiz	3:Koycegiz		0.95
11	3:Koycegiz	3:Koycegiz		0.868
12	3:Koycegiz	3:Koycegiz		0.954
13	3:Koycegiz	3:Koycegiz		0.947
14	4:GokceAgac	4:GokceAgac		0.983
15	4:GokceAgac	4:GokceAgac		0.984
16	4:GokceAgac	4:GokceAgac		0.984
17	4:GokceAgac	4:GokceAgac		0.985
18	4:GokceAgac	4:GokceAgac		0.985
19	5:Camlica	5:Camlica		0.711
20	5:Camlica	5:Camlica		0.874
21	5:Camlica	5:Camlica		0.928
22	5:Camlica	5:Camlica		0.953
23	5:Camlica	5:Camlica		0.969
24	6:DistileSu	6:DistileSu		0.985
25	6:DistileSu	6:DistileSu		0.986
26	7:Uludag	7:Uludag		0.992
27	7:Uludag	7:Uludag		0.98
28	7:Uludag	7:Uludag		0.979
29	7:Uludag	7:Uludag		0.974
30	7:Uludag	7:Uludag		0.983
31	8:SekerPinari	8:SekerPinari		0.974
32	8:SekerPinari	8:SekerPinari		0.972
33	8:SekerPinari	8:SekerPinari		0.978
34	8:SekerPinari	8:SekerPinari		0.979
35	8:SekerPinari	8:SekerPinari		0.982
36	9:KayseriSebeke	9:KayseriSebeke		0.973
37	9:KayseriSebeke	9:KayseriSebeke		0.968
38	9:KayseriSebeke	9:KayseriSebeke		0.955
39	9:KayseriSebeke	9:KayseriSebeke		0.97
40	9:KayseriSebeke	9:KayseriSebeke		0.962
41	10:EtilAlkolYuzdeDoksanAlti	10:EtilAlkolYuzdeDoksanAlti		0.989
42	10:EtilAlkolYuzdeDoksanAlti	10:EtilAlkolYuzdeDoksanAlti		0.984
43	10:EtilAlkolYuzdeDoksanAlti	10:EtilAlkolYuzdeDoksanAlti		0.991
44	10:EtilAlkolYuzdeDoksanAlti	10:EtilAlkolYuzdeDoksanAlti		0.99
45	10:EtilAlkolYuzdeDoksanAlti	10:EtilAlkolYuzdeDoksanAlti		0.988

Verilere ilişkin karışıklık matrisi Şekil 3.14’de verilmiştir. Sistemin genel başarısının oldukça yüksek doğrulukta olduğu görülmektedir. Ayrıca madde kullanılmaksızın elde edilen veriler alkol ile suyun ayrılabilirdiğini göstermektedir. Su içerisinde bulunan

mineral farklılıkları sistem tarafından etil alkol ile büyük doğrulukla karıştırılmamıştır. Madran kaynaklı su dışında karışan bir başka su bulunmamaktadır.

a	b	c	d	e	f	g	h	i	j	<-- classified as
3	0	1	0	0	0	0	0	0	1	a = Madran
0	3	0	0	0	0	0	0	0	0	b = Toros
0	0	5	0	0	0	0	0	0	0	c = Koycegiz
0	0	0	5	0	0	0	0	0	0	d = GokceAgac
0	0	0	0	5	0	0	0	0	0	e = Camlica
0	0	0	0	0	2	0	0	0	0	f = DistileSu
0	0	0	0	0	0	5	0	0	0	g = Uludag
0	0	0	0	0	0	0	5	0	0	h = SekerPinari
0	0	0	0	0	0	0	0	5	0	i = KayseriSebeke
0	0	0	0	0	0	0	0	0	5	j = EtilAlkolYuzdeDoksanAlti

Şekil 3.14. Su ve Etil Alkol Karışıklık Matrisi (176 Özellik İçin Test).

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

Tez çalışmasında; madde ayırımı amaçlı olarak kullanılan spektrofotometreleri ucuzlatmak, otonom olarak sonuçları değerlendirmesini sağlamak aynı zamanda da bu işlemleri gerçekleştirirken yüksek doğrulukta bu işlemleri gerçekleştirebilmek hedeflenmiştir. Bu amaçla maddenin fotometrik özelliklerini kullanan YSA destekli bir sistem geliştirilmiştir. Sistemde; ışık kaynağı olarak 365-950nm arasında 22 farklı LED, sensör olarak ise ışık dijital dönüştürücüsü kullanılmıştır. Kullanılan ışık dijital dönüştürücüsü; geniş spektral aralıkta ve kızılötesi spektral aralıkta çalışan iki farklı fotodiyota, sinyal kuvvetlendiricisine ve 16 bit ADC'ye sahiptir. Kullanılan devre elemanları ile çok hassas çıkışlar elde edilmiş, bu çıkışlar sayesinde birçok sınıflandırma problemini çözebileceği gösterilmiştir.

Sistemin taşınabilir yapısı sayesinde yerinde analize imkan sağlamaktadır. Spektrofotometreler genel olarak maddenin spektral bölgesine ait teknik bilgiler verirken, geliştirmiş olduğumuz sistemimizde kullanılan yapay sinir ağı ile tanıtılan numuneler doğrudan tanınabilmektedir. Yapılan çalışmaların tamamında ayraç madde kullanılmadan alınan sonuçlar sistemimizin başarısını ortaya koymaktadır. Geliştirmiş olduğumuz sistemimiz 365nm-950nm arasında ışık kaynağına sahip olduğu için bir maddenin tanınabilmesi için maddenin bu spektral bölge içerisinde ayırt edilebilir olması gerekmektedir.

Tasarlanan sistemin performansını test etmek için su, süt ve etil alkol üzerinde deneyler yapılmıştır. Sütün markasına göre sınıflandırılmasında çapraz doğrulama ve özellik seçimi kullanılarak %99 doğru sınıflandırma elde edilmiştir. Sistemin daha önce görmediği test verileri sağlandığında ise aynı paketten alınan sütlerin tamamı doğru sınıflandırılmış fakat farklı seri numarasına sahip paketteki sütlerin tamamı başka marka

ile karıştırılmıştır. Bu durum, sütlerin içerdiği maddelerin miktarının paketten pakete değişebildiği şeklinde yorumlanmıştır. İkinci deney olarak sütlerin bekleme süresine göre sınıflandırılması test edilmiş, çapraz doğrulama ile sistemin başarısı %97.5 olarak tespit edilmiştir. Bu deneyde test işlemi gerçekleştirildiğinde karıştırma durumu, 1 gün sapma ile belirlenmiş fakat farklı markaya sahip süt doğru sınıflandırılmamıştır. Üçüncü deneyde kaynağına göre suyun sınıflandırılması denenmiş ve çapraz doğrulama ile %100 doğrulukta sonuç elde edilmiştir. Bu deneye uygulanan test verileri ise %95 doğrulukta sınıflandırılmıştır. Son olarak sistemde kaynağına göre su verileri içerisine etil alkol verileri eklenerek sınıflandırılması denenmiştir. Yapılan deneyde çapraz doğrulama ile %100, test işlemi ile %99.56 başarı elde edilmiştir. Gerçekleştirilen deneylerde, özellik seçimi işleminin doğruluğu artıran etkisi gözlemlenmiştir.

Deneylerde bulunan 176 ölçüm özelliğini inceleyerek maddeyi sınıflandırabilmek oldukça zordur. Bundan dolayı WEKA üzerinde özellik seçimi ve YSA desteği kullanılmıştır. Bu sayede daha hızlı, daha pratik değerlendirme imkanı sağlanmıştır.

Mevcut sisteme daha dar bant genişlikli sensörlerin yerleştirilmesi, 90 derecelik açıda emitans sensörü eklenmesi ya da fotodiyot dizisi eklenilmesi ile sistemdeki ölçüm parametreleri artırılabilir ancak bu yenilikler sonraki çalışmalara bırakılmıştır. Yapılacak çalışmalarda sistemde tekrarlama hatalarını daha da azaltabilmek için redüktörsüz, mikrostep sürücülü, step motor kullanılması planlanmaktadır.

KAYNAKLAR

1. Chandrakala, C., Tharini, G. K., Ananthi, M., Subha, R., 2016. A case of alkaptonuria with degenerative collagenous plaques and foot drop. **Indian Journal of Dermatology**, **61**(6): 678.
2. Peacock, A. D., White, D. C., 2016. Microbial biomass and community composition analysis using phospholipid fatty acids. Hydrocarbon and lipid microbiology protocols. Springer Protocols Handbooks.
3. Olakanmi, E. O., Thompson, O. M., Vunain, E., Doyoyo, M., Meijboom, R., 2016. Effects of Daniella oliveri Wood Flour Characteristics on the Processing and Functional Properties of Wood Polymer Composites. **Materials and Manufacturing Processes**, **31**(8): 1073-1084.
4. Nicoll, K. J., Rose, A. M., Khan, M. A. A., Quaba, O., Lowrie, A. G., 2016. Thigh burns from exploding e-cigarette lithium ion batteries: first case series. **Burns**, **42**(4): e42-e46.
5. Abbasi, M., Mohammadizadeh, M. R., Saeedi, N., 2016. The synthesis of symmetrical disulfides by reacting organic halides with $\text{Na}_2\text{S}_2\text{O}_3 \cdot 5\text{H}_2\text{O}$ in DMSO. **New Journal of Chemistry**, **40**(1): 89-92.
6. Morell-Garcia, D., Bauça, J. M., Barceló, A., Perez-Esteban, G., Vila, M., 2014. Usefulness of Benedict's test for the screening of galactosemia. **Clinical biochemistry**, **47**(9): 857-859.
7. Hess, S. C., Damesceno, G. A., 1994. Of benedict's solution and enzymes—easy experiments. **Biochemical education**, **22**(1): 49-50.
8. Thewes, F. R., Brackmann, A., de Oliveira Anese, R., Ludwig, V., Schultz, E. E., dos Santos, L.F., Wendt, L.M., 2016. Effect of dynamic controlled atmosphere monitored by respiratory quotient and 1-methylcyclopropene on the metabolism and quality of ‘Galaxy’ apple harvested in three maturity stages. **Food Chemistry**.

9. Tonova, K., Bogdanov, M. G., 2016. Partitioning of α -amylase in aqueous biphasic system based on hydrophobic and polar ionic liquid: Enzyme extraction, stripping and purification. **Separation Science and Technology**.
10. Eren, Y., Yavasoglu, N. G., Comoglu, S. S., 2016. Post-traumatic unilateral plantar hyperhidrosis. **Clinical Autonomic Research**, **26**(1): 75-77.
11. Russo, T., Brancaccio, G., 2016. Oral Medication in Hyperhidrosis. In *Hyperhidrosis* (pp. 23-26). Springer International Publishing.
12. Heinig, B., Koch, A., Wollina, U., 2016. Palmar hyperhidrosis treated by noninvasive ultrasound stellate ganglion block. *Wiener Medizinische Wochenschrift*, 1-4.
13. Huang, S., Yao, B., Xie, J., Fu, X., 2016. 3D bioprinted extracellular matrix mimics facilitate directed differentiation of epithelial progenitors for sweat gland regeneration. **Acta biomaterialia**, **32**: 170-177.
14. Madhu, S., Evans, H. A., Doan-Nguyen, V. V., Labram, J. G., Wu, G., Chabinyc, M. L., Seshadri, R., Wudl, F., 2016. Infinite Polyiodide Chains in the Pyrroloperylene–Iodine Complex: Insights into the Starch–Iodine and Perylene–Iodine Complexes. **Angewandte Chemie**, **128**: 8164.
15. Running, J. A., Bansal, K., 2016, Oxygen transfer rates in shaken culture vessels from Fernbach flasks to microtiter plates. **Biotechnol. Bioeng.**, **113**: 1729–1735. doi:10.1002/bit.25938.
16. Shao, H., Liu, X., Zhou, Z., Zhao, B., Chen, Z., Xu, M., 2016. Elemental mercury removal using a novel KI modified bentonite supported by starch sorbent. **Chemical Engineering Journal**, **291**: 306-316.
17. Zheng, Y., Zhang, H., Zhang, B.-J., Yue, L.-H., 2016 A New Method in Detecting the Sticky Rice Component in Traditional Chinese Tabia. **Archaeometry**, **58**: 218–229.
18. Web: https://en.wikipedia.org/wiki/Raman_spectroscopy (Erişim Tarihi: 28.12. 2016)

19. Web: https://www.selcuk.edu.tr/ileri_arge/birim/web/sayfa/ayrinti/29863/tr (Erişim Tarihi:28.12.2016)
20. Niero, G., Penasa, M., Currò, S., Masi, A., Trentin, A. R., Cassandro, M., De Marchi, M., 2017. Development and validation of a near infrared spectrophotometric method to determine total antioxidant activity of milk. **Food Chemistry**, **220**: 371-376.
21. Noor, N. S. M., Tan, L. L., Heng, L. Y., Chong, K. F., Tajuddin, S. N., 2016. Acrylic microspheres-based optosensor for visual detection of nitrite. **Food chemistry**, **207**: 132-138.
22. Musa, K. H., Abdullah, A., Al-Haiqi, A., 2016. Determination of DPPH free radical scavenging activity: application of artificial neural networks. **Food chemistry**, **194**: 705-711.
23. Qiu, H., Gao, L., Wang, J., Pan, J., Yan, Y., Zhang, X., 2017. A precise and efficient detection of Beta-Cyfluthrin via fluorescent molecularly imprinted polymers with ally fluorescein as functional monomer in agricultural products. **Food Chemistry**, **217**: 620-627.
24. Palomba, R., Formisano, G., Arrichiello, A., Auriemma, G., Sarubbi, F., 2016. Development of a laboratory technique for the evaluation of protease enzymes activity in goat and sheep milk. **Food Chemistry**.
25. Frank, C., Meier, D., Voß, D., Zielinski, O., 2014. Computation of nitrate concentrations in coastal waters using an in situ ultraviolet spectrophotometer: Behavior of different computation methods in a case study a steep salinity gradient in the southern North Sea. **Methods in Oceanography**, **9**: 34-43.
26. Baker, A., Ward, D., Lieten, S. H., Periera, R., Simpson, E. C., Slater, M., 2004. Measurement of protein-like fluorescence in river and waste water using a handheld spectrophotometer. **Water Research**, **38**(12): 2934-2938.
27. Devatha, C. P., Thalla, A. K., Katte, S. Y., 2016. Green synthesis of iron nanoparticles using different leaf extracts for treatment of domestic waste water. **Journal of Cleaner Production**, **139**: 1425-1435.

28. Khemakhem, M., Papadimitriou, V., Sotiroudis, G., Zoumpoulakis, P., Arbez-Gindre, C., Bouzouita, N., Sotiroudis, T. G., 2016. Melanin and humic acid-like polymer complex from olive mill waste waters. Part I. Isolation and characterization. **Food chemistry**, **203**: 540-547.
29. Khemakhem, M., Sotiroudis, G., Mitsou, E., Avramiotis, S., Sotiroudis, T. G., Bouzouita, N., Papadimitriou, V., 2016. Melanin and humic acid-like polymer complex from olive mill waste waters. Part II. Surfactant properties and encapsulation in W/O microemulsions. **Journal of Molecular Liquids**, **222**: 480-486.
30. Ferrer, L., de Armas, G., Miró, M., Estela, J. M., Cerdà, V., 2004. A multisyringe flow injection method for the automated determination of sulfide in waters using a miniaturised optical fiber spectrophotometer. **Talanta**, **64**(5): 1119-1126.
31. Takamoto, A., Sugahara, K., Shibahara, T., Katakura, A., Matsuzaka, K., Sugihara, N., 2013. Screening for oral mucosal diseases by a portable spectrophotometer: Comparison between color difference and epithelial thickness. *Journal of Oral and Maxillofacial Surgery, Medicine, and Pathology*, **25**(4): 314-327.
32. Kim, H. E., Kim, B. I., 2015. An in vitro comparison of quantitative light-induced fluorescence-digital and spectrophotometer on monitoring artificial white spot lesions. **Photodiagnosis and photodynamic therapy**, **12**(3): 378-384.
33. Rubio, L., Sioli, J. M., Suarez, J., Gaitan, M. J., Martin-de-las-Heras, S., 2015. Spectrophotometric analysis of color changes in teeth incinerated at increasing temperatures. **Forensic science international**, **252**: 193-e1.
34. Ahmed, S., 2016. Estimation of Total Chlorophyll and Total Carotenoid Contents for Strains of Anabaena and Gloeocapsa Through Spectrophotometer. **Global Journal For Research Analysis**, **5**(7).
35. Sakudo, A., Kato, Y. H., Kuratsune, H., Ikuta, K., 2009. Non-invasive prediction of hematocrit levels by portable visible and near-infrared spectrophotometer. **Clinica Chimica Acta**, **408**(1): 123-127.

36. Guo, Y., Zhao, H., Han, Y., Liu, X., Guan, S., Zhang, Q., Bian, X., 2017. Simultaneous spectrophotometric determination of trace copper, nickel, and cobalt ions in water samples using solid phase extraction coupled with partial least squares approaches. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, **173**: 532-536.
37. Apyari, V. V., Dmitrienko, S. G., Zolotov, Y. A., 2013. Unusual application of common digital devices: Potentialities of Eye-One Pro mini-spectrophotometer—A monitor calibrator for registration of surface plasmon resonance bands of silver and gold nanoparticles in solid matrices. **Sensors and Actuators B: Chemical**, **188**: 1109-1115.
38. Lente, G., Espenson, J. H., 2004. Photoreduction of 2, 6-dichloroquinone in aqueous solution: Use of a diode array spectrophotometer concurrently to drive and detect a photochemical reaction. **Journal of Photochemistry and Photobiology A: Chemistry**, **163**(1): 249-258.
39. Lee, S., Nam, Y. S., Lee, H. J., Lee, Y., Lee, K. B., 2016. Highly selective colorimetric detection of Zn (II) ions using label-free silver nanoparticles. **Sensors and Actuators B: Chemical**, **237**: 643-651.
40. Çetintaş, C., Karakuş, E., Üçüncü, M., Emrullahoğlu, M. 2016. A fluorescein-based chemodosimeter for selective gold (III) ion monitoring in aqueous media and living systems. **Sensors and Actuators B: Chemical**, **234**: 109-114.
41. Web:https://tr.wikipedia.org/wiki/Nükleer_Manyetik_Rezonans_Spektroskopisi (Erişim Tarihi: 28.12.2016)
42. Ochoa, G., Colla, C. A., Klavins, P., Augustine, M. P., Casey, W. H., 2016. NMR spectroscopy of some electrolyte solutions to 1.9 GPa. **Geochimica et Cosmochimica Acta**, **193**: 66-74.
43. Haouas, M., Taulelle, F., Martineau, C., 2016. Recent advances in application of ²⁷Al NMR spectroscopy to materials science. **Progress in nuclear magnetic resonance spectroscopy**, **94**: 11-36.

44. Liu, Q., Zhu, M., 2016. Determination of molar ratio of primary secondary and tertiary amines in polymers by applying derivatization and NMR spectroscopy. **Polymer Testing**, **56**: 174-179.
45. Zhang, M., Xu, S., Li, J., Wei, Y., Gong, Y., Chu, Y., Zheng, A., Wang, J., Zhang, W., Wu, X., Deng, F., Liu, Z., 2016. Methanol to hydrocarbons reaction over H β zeolites studied by high resolution solid-state NMR spectroscopy: Carbenium ions formation and reaction mechanism. **Journal of Catalysis**, **335**: 47-57.
46. Warner, L., Gjersing, E., Follett, S. E., Elliott, K. W., Dzyuba, S. V., Varga, K., 2016. The effects of high concentrations of ionic liquid on GB1 protein structure and dynamics probed by high-resolution magic-angle-spinning NMR spectroscopy. **Biochemistry and Biophysics Reports**, **8**: 75-80.
47. Gopinath, T., Veglia, G., 2016. Orphan Spin Polarization: A Catalyst for High-Throughput Solid-State NMR Spectroscopy of Proteins. **Annual Reports on NMR Spectroscopy**, **89**: 103-121.
48. Zhu, F., 2016. NMR spectroscopy of starch systems. Food Hydrocolloids.
49. Priyadarshini, E., Pradhan, N. 2017. Gold nanoparticles as efficient sensors in colorimetric detection of toxic metal ions: a review. **Sensors and Actuators B: Chemical**, **238**: 888-902.
50. Gondal, M. A., Dastageer, M. A., Al-Adel, F. F., Naqvi, A. A., Habibullah, Y. B. 2015. Detection of highly toxic elements (lead and chromium) in commercially available eyeliner (kohl) using laser induced break down spectroscopy. **Optics & Laser Technology**, **75**: 99-104.
51. Dorantes-Aranda, J.J., Campbell, K., Bradbury, A., et al. 2016. Comparative performance of four immunological test kits for the detection of Paralytic Shellfish Toxins in Tasmanian shellfish. *Toxicon*.

52. Maseda, C., Hayakawa, A., Okuda, K., Asari, M., Tanaka, H., Yamada, H., Jin, S., Horioka, K., Matoba, K., Shiono, H., Shimisu, K., Matsubara, K., 2017. Liquid chromatography-tandem mass spectrometry method for the determination of thiosulfate in human blood and urine as an indicator of hydrogen sulfide poisoning. **Legal Medicine**, **24**: 67-74.
53. Júnior, P. H. R., de Sá Oliveira, K., de Almeida, C. E. R., De Oliveira, L. F. C., Stephani, R., da Silva Pinto, M., Carvalho, A. F., Perrone, Í. T. 2016. FT-Raman and chemometric tools for rapid determination of quality parameters in milk powder: Classification of samples for the presence of lactose and fraud detection by addition of maltodextrin. **Food chemistry**, **196**: 584-588.
54. Rahman, A., Kondo, N., Ogawa, Y., Suzuki, T., Shirataki, Y., Wakita, Y., 2016. Classification of fresh and spoiled Japanese dace (*Tribolodon hakonensis*) fish using ultraviolet–visible spectra of eye fluid with multivariate analysis. **Engineering in Agriculture, Environment and Food**, **9**(1): 64-69.
55. Shimazaki, Y., Watanabe, S., Takahashi, M., Iwatsuki, M., 2000. Portable Spectrophotometer Using a White-Color Light-Emitting Diode and a Charge-Coupled Device and Its Application to On-Site Determination of Iron. **Analytical sciences**, **16**(10): 1091-1093.
56. Chowdhury, S., Mazumder, M. J., Al-Attas, O., Husain, T., 2016. Heavy metals in drinking water: Occurrences, implications, and future needs in developing countries. **Science of The Total Environment**, **569**: 476-488.
57. Venkateswaran, S., Luque-González, M. A., Tabraue-Chávez, M., Fara, M. A., López-Longarela, B., Cano-Cortes, V., López-Delgado, F. C., Sánchez-Martín, R. M., Ilyine, H., Bradley, M., Pernagallo, S., 2016. Novel bead-based platform for direct detection of unlabelled nucleic acids through **Single Nucleobase Labelling**. **Talanta**, **161**: 489-496.
58. Honeker, L. K., Root, R. A., Chorover, J., Maier, R. M., 2016. Resolving colocalization of bacteria and metal (loid) s on plant root surfaces by combining fluorescence in situ hybridization (FISH) with multiple-energy micro-focused X-ray fluorescence (ME μ XRF). **Journal of Microbiological Methods**, **131**: 23-33.

59. Karuppiah, K., Senthilkumar, T., Jayas, D. S., White, N. D. G. 2016. Detection of fungal infection in five different pulses using near-infrared hyperspectral imaging. **Journal of Stored Products Research**, **65**: 13-18.
60. Trojanowicz, M., Worsfold, P. J., Clinch, J. R., 1988. Solid-state photometric detectors for flow injection analysis. **TrAC Trends in Analytical Chemistry**, **7**(8): 301-305.
61. Worsfold, P. J., Clinch, J. R., Casey, H., 1987. Spectrophotometric field monitor for water quality parameters: the determination of phosphate. **Analytica Chimica Acta** **197**: 43-50.
62. Ellis, P. S., Lyddy-Meaney, A. J., Worsfold, P. J., McKelvie, I. D., 2003. Multi-reflection photometric flow cell for use in flow injection analysis of estuarine waters. **Analytica Chimica Acta**, **499**(1): 81-89.
63. Blundell, N. J., Worsfold, P. J., Casey, H., Smith, S., 1995. The design and performance of a portable, automated flow injection monitor for the in-situ analysis of nutrients in natural waters. **Environment international**, **21**(2): 205-209.
64. Gardolinski, P. C., David, A. R., Worsfold, P. J., 2002. Miniature flow injection analyser for laboratory, shipboard and in situ monitoring of nitrate in estuarine and coastal waters. **Talanta**, **58**(6): 1015-1027.
65. Clinch, J. R., Worsfold, P. J., Casey, H., 1987. An automated spectrophotometric field monitor for water quality parameters: Determination of nitrate. **Analytica Chimica Acta**, **200**: 523-531.
66. David, A. R., McCormack, T., Morris, A. W., Worsfold, P. J., 1998. A submersible flow injection-based sensor for the determination of total oxidised nitrogen in coastal waters. **Analytica Chimica Acta**, **361**(1): 63-72.
67. Andrew, K. N., Worsfold, P. J., Comber, M., 1995. On-line flow injection monitoring of ammonia in industrial liquid effluents. **Analytica Chimica Acta**, **314**(1): 33-43.

68. O'Toole, M., Lau, K. T., Shepherd, R., Slater, C., Diamond, D., 2007. Determination of phosphate using a highly sensitive paired emitter–detector diode photometric flow detector. **Analytica chimica acta**, **597**(2): 290-294.
69. Lu, Q., Collins, G. E., Smith, M., Wang, J., 2002., Sensitive capillary electrophoresis microchip determination of trinitroaromatic explosives in nonaqueous electrolyte following solid phase extraction. **Analytica Chimica Acta**, **469**(2): 253-260.
70. O'Toole, M., Diamond, D. 2008. Absorbance based light emitting diode optical sensors and sensing devices. **Sensors**, **8**(4): 2453-2479.
71. Frazzoli, E., Dahleh, M. A., Feron, E. 2002. Real-time motion planning for agile autonomous vehicles. Journal of Guidance, **Control, and Dynamics**, **25**(1): 116-129.
72. Vanderhaegen, F. 2016. A rule-based support system for dissonance discovery and control applied to car driving. **Expert Systems with Applications**, **65**: 361-371.
73. Betteridge, D., Dagless, E. L., Fields, B., Graves, N. F., 1978. A highly sensitive flow-through phototransducer for unsegmented continuous-flow analysis demonstrating high-speed spectrophotometry at the parts per 10⁹ level and a new method of refractometric determinations. **Analyst**, **103**(1230): 897-908.
74. Hauser, P. C., Chiang, D. W., 1993. A photometric detector based on a blue light-emitting diode. **Talanta**, **40**(8): 1193-1200.
75. Matias, F. A., Vila, M. M., Tubino, M., 2003. A simple device for quantitative colorimetric diffuse reflectance measurements. **Sensors and Actuators B: Chemical**, **88**(1): 60-66.
76. Tubino, M., de Souza, R. L., 2006. Determination of diclofenac in pharmaceutical preparations by diffuse reflectance photometry. **Talanta**, **68**(3):776-780.
77. Tubino, M., Queiroz, C. A., 2007. Flow injection visible diffuse reflectance quantitative analysis of nickel. **Analytica chimica acta**, **600**(1): 199-204.

78. Liu, H., Dasgupta, P. K., 1994. Dual-wavelength photometry with light emitting diodes. Compensation of refractive index and turbidity effects in flow-injection analysis. **Analytica chimica acta**, **289**(3): 347-353.
79. Suzuki, A., Kondoh, J., Matsui, Y., Shiokawa, S., Suzuki, K., 2005. Development of novel optical waveguide surface plasmon resonance (SPR) sensor with dual light emitting diodes. **Sensors and Actuators B: Chemical**, **106**(1): 383-387.
80. Zagatto, E. A. G., Arruda, M. A. Z., Jacintho, A. O., Mattos, I. L., 1990. Compensation of the schlieren effect in flow-injection analysis by using dual-wavelength spectrophotometry. **Analytica Chimica Acta**, **234**, 153-160.
81. Eom, I. Y., Dasgupta, P. K., 2006. Frequency-selective absorbance detection: Refractive index and turbidity compensation with dual-wavelength measurement. **Talanta**, **69**(4), 906-913.
82. Hauser, P. C., Rupasinghe, T. W., Cates, N. E., 1995. A multi-wavelength photometer based on light-emitting diodes. **Talanta**, **42**(4): 605-612.
83. Fonseca, A., Raimundo, I. M. 2004. A multichannel photometer based on an array of light emitting diodes for use in multivariate calibration. **Analytica Chimica Acta**, **522**(2): 223-229.
84. Beach, J. M., 1997. A LED light calibration source for dual-wavelength microscopy. **Cell calcium**, **21**(1): 63-68.
85. Schnable, J. G., Grochowski, P. J., Wilhelm, L., Harding, C., Kiefer, M., Orr, R. S., 1998. Portable LED-array VIS–NIR spectrophotometer/nephelometer. **Field Analytical Chemistry & Technology**, **2**(1): 21-28.
86. Suzuki, Y., Hori, H., Iwatsuki, M., Yamane, T., 2003. A four-wavelength channel absorbance detector with a light emitting diode-fiber optics assembly for simplifying the flow-injection analysis system. **Analytical sciences**, **19**(7): 1025-1028.
87. Cantrell, K. M., Ingle, J. D., 2003. The SLIM spectrometer. **Analytical chemistry**, **75**(1), 27-35.

88. Zude, M., Birlouez-Aragon, I., Paschold, P. J., Rutledge, D. N., 2007. Non-invasive spectrophotometric sensing of carrot quality from harvest to consumption. **Postharvest Biology and Technology**, 45(1): 30-37.
89. Fonseca, A., Raimundo, I. M., 2007. A simple method for water discrimination based on an light emitting diode (LED) photometer. **Analytica chimica acta**, 596(1): 66-72.
90. Web: <http://diyot.net/rgb-led/> (Erişim tarihi:28.11.2016)
91. Web: <https://serdara.com/renk-teorisi-rgb-cmyk/> (Erişim tarihi: 28.11.2016)
92. Lau, K. T., Baldwin, S., Shepherd, R. L., Dietz, P. H., Yerezunis, W. S., Diamond, D., 2004. Novel fused-LEDs devices as optical sensors for colorimetric analysis. **Talanta**, 63(1): 167-173.
93. Lau, K. T., Yerezunis, W. S., Shepherd, R. L., Diamond, D., 2006. Quantitative colorimetric analysis of dye mixtures using an optical photometer based on LED array. **Sensors and Actuators B: Chemical**, 114(2): 819-825.
94. Kayı, H., Alper, E., Tuncel S. A., Yapay Sinir Ağları Modeli İle N-İzopropilakrilamid-Akrilik Asit Kopolimerinin Alt Kritik Çözelti Sıcaklığının Tahmini (<http://ukmk11.ogu.edu.tr/arsiv/ukmk5/Html/SozSunum/Proses/PSM-06.htm>) (Erişim Tarihi:07.08.2016)
95. Sağıroğlu, Ş., Beşdok, E., Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-1. Ufuk Yayıncılık, Kayseri, 426 s.
96. Web: <https://tr.wikipedia.org/wiki/MATLAB> (Erişim Tarihi:11.12.2016)
97. Web: <https://www.mathworks.com/help/nnet/ref/nntool.html> (Erişim Tarihi: 11.12.2016)
98. Web: <https://tr.wikipedia.org/wiki/Weka> (Erişim Tarihi: 11.12.2016)
99. Naik, A., Samant, L., 2016. Correlation Review of Classification Algorithm Using Data Mining Tool: WEKA, Rapidminer, Tanagra, Orange and Knime. **Procedia Computer Science**, 85: 662-668.

100. Web: <http://scitechconnect.elsevier.com/explaining-color-constancy/> (Eriřim Tarihi:17.12.2016)
101. Web: <http://ledmuseum.candlepower.us/specx31.htm> (Eriřim Tarihi:17.12.2016)
102. Kuntzleman, T. S., Jacobson, E. C., 2016. Teaching Beer's Law and Absorption Spectrophotometry with a Smart Phone: A Substantially Simplified Protocol. **Journal of Chemical Education**, **93**: 1249–1252
103. Semiconductors, P., 2002. PCF8574 Remote 8-bit I/O Expander for I2C-bus. Philips Semiconductors.
104. TSL2560, T. A. O. S. TSL2561 light-to-digital converter. 2009-11-01. <http://www.taosinc.com/productsearch.aspx>.
105. Web: <http://weka.sourceforge.net/doc.dev/weka/classifiers/functions/MultilayerPerceptron.html> (Eriřim Tarihi:10.12.2016)
106. Web: <http://www.ibrahimcayiroglu.com/dokumanlar/ilerialgoritmaanalizi/ilerialgoritmaanalizi-5.hafta-yapaysiniraglari.pdf> (Eriřim Tarihi 13.12.2016)
107. Web: <http://www.geocities.ws/kimyaciyim/molekulmodeli/organik/etilalkol.jpg> (Eriřim Tarihi 13.12.2016)
108. Web: <http://butane.chem.uiuc.edu/pshapley/Enlist/Labs/Clouds/Clouds.html> (Eriřim Tarihi 13.12.2016)

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Ekrem Kürşad DAL

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 20 Şubat 1988, Kayseri

Medeni Durumu: Bekâr

Tel: +90 555 716 05 65

email: ekremdal@hotmail.com

Yazışma Adresi: Y. Beyazıt Mah. Kümbetler Sok. Demirpark Plus Apt. A Blok

No:10/19 Melikgazi/Kayseri

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	EÜ Elektrik Elektronik Müh.	2012
Lisans	Anadolu Üniversitesi İşletme	2013
Lise	Sami Yangın Anadolu Lisesi, Kayseri	2006

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2013	Erciyes Teknoloji Transfer Ofisi	Envanter Sorumlusu
2014	Ekrem Kürşad DAL-ELA Mühendislik	İşletme Sahibi

YABANCI DİL

İngilizce