

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

**TAHİL TORBALAMA SİSTEMLERİNDE (SILOBAG) KABLOSUZ
ALGILAYICI AĞ (KAA) TEMELLİ TAHİL DURUM İZLEME**

**Hazırlayan
Canset KOÇER BAYKARA**

**Danışman
Dr. Öğr. Üyesi Muzaffer KANAAN**

Yüksek Lisans Tezi

**Haziran 2018
KAYSERİ**

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

**TAHİL TORBALAMA SİSTEMLERİNDE (SILOBAG) KABLOSUZ
ALGILAYICI AĞ (KAA) TEMELLİ TAHİL DURUM İZLEME
(Yüksek Lisans Tezi)**

**Hazırlayan
Canset KOÇER BAYKARA**

**Danışman
Dr. Öğr. Üyesi Muzaffer KANAAN**

Bu çalışma; Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından FYL-2017-7141 kodlu proje ile desteklenmiştir.

**Haziran 2018
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.

Canset KOÇER BAYKARA

“Tahıl Torbalama Sistemlerinde (Silobag) Kablosuz Algılayıcı Ağ (KAA) Temelli Tahıl Durum İzleme” adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Hazırlayan

Canset KOÇER BAYKARA

Danışman

Dr. Öğr. Üyesi Muzaffer KANAAN

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

Dr. Öğr. Üyesi Muzaffer KANAAN danışmanlığında **Canset KOÇER BAYKARA** tarafından hazırlanan “**Tahıl Torbalama Sistemlerinde (Silobag) Kablosuz Algılayıcı Ağ (KAA) Temelli Tahıl Durum İzleme**” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **Mekatronik Mühendisliği** Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

25 /07 / 2018

JÜRİ:

Danışman : Dr. Öğr. Üyesi Muzaffer KANAAN

Üye : Prof. Dr. Şahin YILDIRIM

Üye : Doç. Dr. Ali ÖZEN

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun .../.../2018 tarih ve sayılı kararı ile onaylanmıştır.

..... /...../

Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

ÖNSÖZ / TEŞEKKÜR

Çalışmalarım boyunca farklı bakış açıları ve bilimsel katkılarıyla beni aydınlatan, yakın ilgi ve yardımlarını esirgemeyen ve bugünlere gelmemde en büyük katkı sahibi danışmanım sayın hocam Dr. Öğr. Üyesi Muzaffer KANAAN'a teşekkürü bir borç bilirim.

Bu tez çalışmasında yardım ve ilgisini esirgemeyen ve bilgi birikimi ile beni aydınlatan Mekatronik Mühendisliği Bölümünde görev yapan değerli hocam Arş. Gör. Memduh SUVEREN ile Seyrani Ziraat Fakültesi'nde görev yapan Öğr. Gör. Zeynel Abidin KUŞ'a içten teşekkürlerimi sunarım.

Tez çalışmama başladığım ilk zamanlarda hakim olmadığım ancak tez çalışmamdaki deneysel süreçlerin önemli bir kısmına ait süreçte tarla bitkileri konusunda beni aydınlatan ve bu konuda kapsamlı bilgi edinmemi sağlayan, yakın ilgi ve desteğini esirgemeyen Seyrani Ziraat Fakültesi'nde görev yapan sayın hocam Arş. Gör. Dr. Hamdi ÖZAKTAN'a teşekkür ederim.

Bu tez çalışmasına maddi destek veren Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne (Proje No: FYL-2017-7141) teşekkür ederim.

Tez çalışmama ait tüm süreçte bir an bile destek ve yardımlarını esirgemeyen ve her zaman beni motive ederek giriştiğim tüm çalışmalarımın başarıyla üstesinden gelmemi sağlayan sevgili eşim Sercan BAYKARA'ya en derin teşekkürlerimi sunarım.

Ayrıca; çalışmalarım süresince sabrını, sevgisini ve desteğini esirgemeyerek beni daima destekleyen annem ve babama içtenlikle teşekkür ederim.

Canset KOÇER BAYKARA

Haziran 2018, Kayseri

TAHİL TORBALAMA SİSTEMLERİNDE (SILOBAG) KABLOSUZ ALGILAYICI AĞ (KAA) TEMELLİ TAHİL DURUM İZLEME

Canset KOÇER BAYKARA

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Haziran 2018

Danışman: Dr. Öğr. Üyesi Muzaffer KANAAN

ÖZET

Toprak Mahsulleri Ofisi (TMO) bünyesinde açık yığınlarda yapılan depolamaya alternatif olarak kullanılmakta olan Tahıl Torbalama (Silobag) Sisteminin ekipmanlarından biri olan mevcut Tahıl Kontrol Sisteminde ölçümlerin operatör vasıtasıyla yapılması fazla iş gücüne neden olmakta ve bu sisteme göre yapılan ölçümler sadece CO₂ oranına göre yapıldığından tahılın bozulması sağlıklı olarak izlenip tespit edilememektedir. Ayrıca mevcut Tahıl Kontrol Sisteminde veriler Arjantin merkezli teminci firmaya gönderilerek yorumlandığından bu durum TMO açısından dışa bağımlılık oluşturmakta ve verilerin gizliliği açısından sorun teşkil etmektedir. Mevcut sisteme ait bu problemlerinin giderilmesi amacıyla bu tez çalışmasında yeni bir Tahıl Kontrol Sistemi tasarlanmıştır. Tasarlanan bu sistemde CO₂ oranı yerine güvenli tahıl depolamada önemli parametreler olan sıcaklık ve nem verileri kablosuz sensör düğümleri vasıtasıyla otomatik olarak elde edilebilmekte ve bu veriler sistemin veri tabanına kaydedilerek kullanıcı ara yüzü vasıtasıyla anlık olarak izlenip yorumlanabilmektedir. Geliştirilen yeni kontrol sisteminde sınıflandırıcı olarak Matlab üzerinden Yapay Sinir Ağları (YSA) kullanılmış ve tahılın durumu “Güvenli”, “Riskli” ve “Tehlikeli” olarak 3 farklı sınıfa ayrılmıştır. YSA sınıflandırıcısının oluşturulmasında ise Matlab üzerinden optimum parametre değerleri tespit edilerek üç farklı eğitim algoritması (Traingdm, Trainlm, Trainscg) için karşılaştırma yoluyla en iyi başarımların oranı bulunmuştur. En iyi performansı %98,99 başarımların oranı ile “Traingdm” algoritması göstermiştir. Son olarak geliştirilen Tahıl Kontrol Sisteminden anlık olarak elde edilen verilerin kullanıcıya kolaylıkla sınıflandırılarak gösterilmesi amacıyla Matlab GUI tasarlanmıştır.

Anahtar Kelimeler: TMO, Silobag, Tahıl Kontrol Sistemi, Kablosuz Sensör Düğümleri, YSA, Matlab, GUI

WIRELESS NETWORK BASED GRAIN CONTROL SYSTEM DESIGN FOR GRAIN BAGGING SYSTEM (SILOBAG)

Canset KOÇER BAYKARA

Erciyes University, Graduate School of Natural and Applied Sciences

M. Sc. Thesis, June 2018

Supervisor: Dr. Muzaffer KANAAN

ABSTRACT

Turkish Grain Board (TMO) uses Grain Bagging (Silobag) System as an alternative to the open (outdoor) grain pile storage. One of the components of Grain Bagging System is the Grain Control System. In the existing Grain Control System, measurements are made by operator and this causes excessive workload. Besides, the corruption of the grain cannot always be accurately diagnosed since the measurements are made only on the CO₂ rate. Moreover, the data in the existing Grain Control System is sent to the agency based in Argentina and this situation creates external dependency for TMO and poses a problem in terms of confidentiality of the data. To solve these problems, a new Grain Control System was designed in this research. In this new system, temperature and humidity data, which are important parameters in safe grain storage, can be obtained automatically by wireless sensor nodes. This data can be saved in the database of the system, monitored and interpreted instantly through the user interface. In the new control system, Artificial Neural Network (ANN) was used as a classifier through Matlab and the state of the grain was divided into 3 different classes as "Safe", "Risky" and "Dangerous". In the creation of the ANN classifier, optimum parameter values were determined through Matlab and the best performance ratio was found by comparing the three different training algorithms (Traingdm, Trainlm, Trainscg). The best performance is the "Traingdm" algorithm with 98.99% performance ratio. Finally, Matlab GUI was designed to make the classified data easily comprehensible for the user.

Keywords: TMO, Silobag, Grain Control System, Wireless Sensor Nodes, ANN, MATLAB, GUI

İÇİNDEKİLER

TAHİL TORBALAMA SİSTEMLERİNDE (SILOBAG) KABLOSUZ ALGILAYICI AĞ (KAA) TEMELLİ TAHİL DURUM İZLEME

	<u>Sayfa</u>
BİLİMSEL ETİĞE UYGUNLUK	ii
YÖNERGEYE UYGUNLUK.....	iii
KABUL VE ONAY SAYFASI	iv
ÖNSÖZ / TEŞEKKÜR	v
ÖZET	vi
ABSTRACT	vii
İÇİNDEKİLER	viii
KISALTMALAR VE SİMGELER.....	xi
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ	xiv
 GİRİŞ	 1

1.BÖLÜM

MEVCUT TAHİL TORBALAMA SİSTEMİ, PROBLEMLERİ VE GÜVENLİ TAHİL DEPOLAMA

1.1. Mevcut Tahıl Torbalama Sistemi	6
1.1.1. Tahıl Kontrol Sistemi	8
1.2. Mevcut Tahıl Torbalama Sisteminin Problemleri	10
1.3. Güvenli Tahıl Depolama.....	12

2.BÖLÜM

TARIMSAL UYGULAMALARDA KABLOSUZ HABERLEŞME TEKNOLOJİLERİ

2.1. Kablosuz Haberleşme Teknolojisi	15
2.2. Literatürdeki Tarımsal Uygulamalarda Kablosuz Haberleşme Teknolojileri.	15

3.BÖLÜM

MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRMA

3.1. Makine Öğrenmesi ve Öğrenme Stratejileri	19
3.2. Sınıflandırma ve Yapay Sinir Ağları.....	23
3.3. Yapay Sinir Ağları ile Tarımsal Ürünlerin Sınıflandırılması.....	30

4. BÖLÜM

MATERYAL VE METOT

4.1. Kablosuz Sensör Düğümü Tasarımı.....	35
4.2. Kullanıcı Ara yüzü ve Veri Tabanı Tasarımı.....	41
4.3. Tasarlanan Tahıl Kontrol Sistemi ile YSA Veri Tabanlarının Oluşturulması	44
4.4. Yapay Sinir Ağının Eğitiminde Kullanılacak Parametrelerin Seçimi	50
4.4.1. Traingdm Algoritması Kullanılarak En Uygun Ortak Parametrelerin Tespiti.....	51
4.4.2. Ortak Parametreler Kullanılarak Trainlm Özel Parametrelerinin Tespiti.....	57
4.4.3. Ortak Parametreler Kullanılarak Trainscg Özel Parametrelerinin Tespiti.....	60
4.5. YSA ile Verilerin Eğitimi ve Test Edilmesi	63
4.6. Matlab Grafiksel Kullanıcı Ara Yüzü (GUI)Tasarımı.....	67

5. BÖLÜM

BULGULAR

5.1. Tahıl Torbalarına ait Sıcaklık ve Nem Verilerinin Değerlendirilmesi	70
5.2. Eğitim Aşamasında Elde Edilen Sonuçların Değerlendirilmesi	76
5.3. Test Aşamasında Elde Edilen Sonuçların Değerlendirilmesi	77

6. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER BÖLÜMÜ

6.1 Tartışma, Sonuç	81
6.2. Öneriler	82

KAYNAKLAR	84
------------------------	-----------

ÖZGEÇMİŞ.....	92
----------------------	-----------

KISALTMALAR VE SİMGELER

<u>Sembol</u>	<u>Anlamı</u>	<u>Birimi</u>
TMO	Toprak Mahsulleri Ofisi	
KAA	Kablosuz Algılayıcı Ağ	
ANN	Artificial Neural Network	
YSA	Yapay Sinir Ağları	
Silobag	Tahıl Torbası	
	Tahıl Torbalama	
MATLAB	Matris Laboratuvarı (Matrix Laboratory)	
GUI	Grafiksel Kullanıcı Arayüzü (Graphical User Interface)	
CO ₂	Karbondioksit	
Nntool	Sinir Ağı Araç Kutusu (Neural Network Toolbox)	
GPRS	Genel Paket Radyo Servisi (General Packet Radio Service)	
M2M	Makineden Makineye Haberleşme (Machine-to-Machine)	
BPNN	Geri Yayılım Sinir Ağı (Back Propagation Neural Network)	
MSE	Hata Kareleri Ortalaması (Mean Square Error)	
Traingdm	Momentumlu Dereceli Azalma Algoritması (Gradient Descent with Momentum Algorithm)	
Trainlm	Levenberg-Marquardt Eğitim Algoritması	
Trainscg	Ölçeklendirilmiş Eşlenik Yaklaşımı Eğitim Algoritması (Scaled Conjugate Gradient Algorithm)	

TABLOLAR LİSTESİ

Tablo 3. 1. Aktivasyon Fonksiyonu Örnekleri	28
Tablo 4. 1. SHT 10 Sıcaklık Nem Sensörüne ait Teknik Özellikler	36
Tablo 4. 2. Raspberry Pi 3 Teknik Özellikleri	37
Tablo 4. 3. Kablosuz Modem Teknik Özellikleri	40
Tablo 4. 4. Silobag Torbalarındaki Tahıla Ait Tanecik Suyu Oranları.....	46
Tablo 4. 5. 1 No.lu Silobag Torbasından Elde Edilen Veriler	47
Tablo 4. 6. Tehlikeli Olarak Etiketlenen Pet Şişedeki Tahıla Ait Veriler.....	47
Tablo 4. 7. Tehlikeli Tahıla Ait Veriler	49
Tablo 4. 8. 3 No.lu Tahıl Torbasına Ait Veriler.....	49
Tablo 4. 9. Sınıflandırılacak Tahıllara İlişkin Elde Edilen Veriler	50
Tablo 4. 10. Aktivasyon Fonksiyonunun Tespiti	52
Tablo 4. 11. Öğrenme Katsayısı Tespiti.....	53
Tablo 4. 12. Momentum Katsayısı Tespit Tablosu	54
Tablo 4. 13. Çevrim Sayısının Tespiti	55
Tablo 4. 14. Nöron Sayısının Tespiti	56
Tablo 4. 15. Gizli Katman Sayısının Tespiti.....	57
Tablo 4. 16. Ağa Ait Optimum Ortak Parametre Değerleri	57
Tablo 4. 17. Trainlm Algoritmasında μ (mu) Değerinin Tespiti	59
Tablo 4. 18. Trainlm Algoritmasında μ_{dec} Değerinin Tespiti	60
Tablo 4. 19. Trainscg Algoritması için Sigma ve Lambda Değerlerinin Tespiti.....	62
Tablo 4. 20. Traingdm, Trainlm ve Trainscg için Elde Edilen Optimum Değerler	63
Tablo 4. 21. YSA Çıktı Verileri	64
Tablo 4. 22. YSA Eğitim ve Test Verilerinin Kısa Gösterimi	64

Tablo 5. 1. Üründeki Su Oranı ve Belirli Sıcaklığa Göre Bağlı Nem	73
Tablo 5. 2. Üründeki Su Oranı ve Belli Sıcaklığa Göre Bağlı (Nıspî) Nem (İnterpolasyon Metodu ile Genişletilmiş)	75
Tablo 5. 3. YSA Özet Başarı Tablosu.....	78
Tablo 5. 4. Her Bir Eğitim Algoritması için Elde Edilen Başarı Yüzdeleri.....	79

ŞEKİLLER LİSTESİ

Şekil 1. Mevcut Tahıl Kontrol Sistemi	3
Şekil 1. 1. Tahıl Torbalama Sistemi.....	7
Şekil 1. 2. Tahıl Depolama Torbası	7
Şekil 1. 3. Ölçüm Noktaları ve RFID Etiketinin Şematik Gösterimi.....	8
Şekil 1. 4. CO ₂ Ölçüm Cihazı	9
Şekil 1. 5. Tahıl Tanecik Suyu Oranı ve CO ₂ Ölçümüne Bağlı Referans Grafiği	9
Şekil 1. 6. Web İzleme Sistemi Ana Menü Ekran Görüntüsü.....	10
Şekil 2. 1. Kablosuz Sensör Ağları ile İklim Koşullarının İzlenmesi	16
Şekil 3. 1. Öğrenme Stratejilerinin Sınıflandırılması	21
Şekil 3. 2. Danışmanlı Öğrenme Süreci	23
Şekil 3. 3. Yapay Sinir Ağı Hücresinin Yapısı	26
Şekil 3. 4. Biyolojik Sinir Hücresi	27
Şekil 3. 5. Yapay Sinir Ağı Yapısı ve Katmanların Birbiri ile İlişkileri	29
Şekil 4. 1. Kablosuz Algılayıcı Ağ Temelli Tahıl Kontrol Sistem Mimarisi.....	33
Şekil 4. 2. Tahıl Kontrol Sistemi Şematik Gösterimi	34
Şekil 4. 3. SHT 10 Sıcaklık Nem Sensörü ve Sensöre ait Kablo Bağlantıları	36
Şekil 4. 4. Raspberry Pi 3 Cihazı	37
Şekil 4. 5. Raspberry Pi 3 Pin Diagramı	38
Şekil 4. 6. Sensör Bağlantıları.....	39
Şekil 4. 7. Kablosuz Modem	39
Şekil 4. 8. Kablosuz Sensör Düğümü Şematik Gösterim.....	40
Şekil 4. 9. Kullanıcı Arayüzü Konfigürasyon Sayfası	42
Şekil 4. 10. Kullanıcı Arayüzü Durum Sayfası.....	43

Şekil 4. 11. Durum Sayfasında Sensörlere Ait Verilerin Listelendiği Bölüm	43
Şekil 4. 12. Nem Ölçme Cihazı.....	45
Şekil 4. 13. Tahıl Torbalarının Ağızlarının Kapatılmasının Gösterimi	46
Şekil 4. 14. Prototip Tahıl Torbaları	46
Şekil 4. 15. Tahılın Kontrollü Olarak Bozulması	48
Şekil 4. 16. Tehlikeli (Bozulmuş) Tahıl.....	48
Şekil 4. 17. YSA Tahıl Durum Sınıflandırıcı Oluşturulması Aşamaları	66
Şekil 4. 18. Tasarlanan GUI Şablonu.....	68
Şekil 4. 19. Tasarlanan GUI Arayüzü	69
Şekil 5. 1. Güvenli Tahıl Sıcaklık –Nem Grafiği.....	71
Şekil 5. 2. Riskli Tahıl Sıcaklık –Nem Grafiği	71
Şekil 5. 3. Tehlikeli Tahıl Sıcaklık –Nem Grafiği	71
Şekil 5. 4. Her bir Tahıl Sınıfına ait Sıcaklık Grafiği	72
Şekil 5. 5. Her bir Tahıl Sınıfına ait Nem Grafiği.....	72
Şekil 5. 6. Ağ Eğitim Performans Grafikleri	76
Şekil 5. 7. Ağ Başarı Oranı Grafiği.....	80
Şekil 6. 1. Mevcut Depolama Sistemlerinde Kullanılan Sıcaklık İzleme Sistemi	82

GİRİŞ


Kablosuz iletişim ve sayısal elektronik teknolojilerindeki gelişmelerle birlikte Kablosuz Algılayıcı Ağları (KAA) geniş yelpazede; askeri uygulamalar, bitki, hayvan izleme, hava durumu tahmini, akıllı ev ve ofis uygulamaları, orman yangını, sel, deprem gibi doğal afetlerin ölçümlendirilmiş olarak hızlı bir şekilde ihbar edilmesi ve sağlık uygulamaları gibi birçok alanda kendini etkin bir şekilde göstermektedir [1].

Kablosuz haberleşme teknolojilerinde son yıllarda yaşanan hızlı gelişmelerin tarımsal faaliyetlerde de uygulanması; özellikle insan iş gücünün azaltılması, çiftçi refahının sağlanması, üretimin daha verimli ve kaliteli yapılması açısından kaçınılmaz olmuştur [2]. Günümüzde, hassas tarımda KAA çok dikkat çeken önemli bir alandır. Hassas tarım, ürün kalitesini artırmak, üretimi geliştirmek ve çevreyi korumak için, doğru zamanda ve doğru yerde doğru miktarda su, gübre, pestisit vb. uygulanması tekniğidir. Genellikle KAA çok fonksiyonlu, düşük güç tüketimi ve düşük maliyetli algılayıcı düğümleri ile kısa mesafelerde iletişim oluşturmaktadır. Bu ağlar ile fiziksel olgularla (hava sıcaklığı, toprak nemi, toprak gerilmeleri, böcek-hastalık-yabancı ot istilasısı gibi) ilgili parametreler izlenerek tarımsal üretimdeki verim arttırılabilir ve tarımsal kalkınmadaki sürdürülebilirlik geliştirilebilir [3].

Özellikle hassas tarımla elde edilen tahıl ürünlerinin depolanması da tarımda sürekliliğin sağlanması açısından önemli bir yer teşkil etmektedir. Tahıl depolama sistemlerinde tahıl kalitesini uzun vadede koruyabilmek, hem tüketiciler için hem de tahıldan kar sağlayan üretici için önemli bir unsurdur. Bu kapsamda Türkiye’de başta hububat olmak üzere tarımsal faaliyet alanında ürün piyasalarını düzenleme görevi bir Kamu İktisadi Teşebbüsü olan Toprak Mahsulleri Ofisi (TMO) tarafından yürütülmektedir. TMO bu görevini faaliyet alanına giren tahıl ürünlerinin (arpa, buğday, mısır, çeltik gibi) alım ve satışını yapmak, gerekli stok tesisini ve muhafazasını sağlamak ile bu ürünlerin piyasalarında istikrar sağlamak suretiyle gerçekleştirmektedir.

TMO, söz konusu ürünlerin stok tesisini ve muhafazasını ise Türkiye genelinde yaklaşık 4 milyon ton çeşitli tonaj ve tiplerde kapalı depo ile sağlamaktadır. Kapalı depoların yetersiz kaldığı durumlarda tahıl ürünleri toprak altında açık yığınlarda depolanmaktadır. TMO açık yığınlarda yapılan depolamaya alternatif olarak Tahıl Torbalama (Silobag) Sistemi kullanımına öncülük etmiştir. TMO bu sistemle tahıl ürünlerinin depolanmasında işçilik, zaman kaybının açık yığınlara göre azaltılması, ürünlerin daha uygun ve modern şartlarda depolanması amaçlamaktadır [4]. Tahıl Torbalama Sisteminin ekipmanlarından biri olan Tahıl Kontrol Sistemi ile tahıl torbası içerisindeki tahıl izlenerek kullanıcıya tahıl durumu hakkında bilgi verilmesi ve bu sayede tahıl depolanmasına ilişkin gerekli önlemlerin alınması sağlanabilmektedir.

Tahıl Kontrol Sistemi tahılın durumuna ilişkin bilgiyi tahıl içerisindeki haşereler ve mikroorganizmaların solunumuna bağlı olarak ortaya çıkan CO₂ oranından elde etmektedir. Tahılda bulunan CO₂ oranı ise, CO₂ Ölçüm Cihazı ile belli periyotlarda izlenmektedir. CO₂ oranına ilişkin veriler, bilgisayara yüklenerek GPRS teknolojisiyle merkez sunucuya iletilmektedir. Bu veriler daha sonra tahılın depolanma koşullarıyla ilgili önceki araştırma verileriyle hazırlanmış referans grafik ile kıyaslanarak depolanan tahılın güncel durumu yorumlanmaktadır. Bu yorumlama yapılırken tahıl torbasının ilk doldurulmasındaki tahıl nem içeriği, konum, ortalama çevre sıcaklığı, depolanma zamanı, önceki CO₂ verileri, torbanın yırtık olup olmaması gibi parametreler de dikkate alınır. Tüm bu veriler ve parametreler ışığında tahıl güvenli, riskli, tehlikeli olarak 3 ayrı kısımda sınıflandırılır. Sınıflandırılmış tahıla ait durum verileri, müşteri bilgileri, tahıl cinsi ve nem içeri, depolanma zamanı ve torbanın konumu gibi bilgiler web tabanlı izleme sistemi ile kullanıcıya ulaştırılmaktadır. Şekil 1’de mevcut Tahıl Kontrol Sistemini açıklayan şematik gösterim belirtilmiştir.



Şekil 1. Mevcut Tahıl Kontrol Sistemi

Tahıl Kontrol Sistemi açık yığınlara göre modern depolama sistemi olmakla birlikte, geliştirilmeye açık bazı yönleri bulunmaktadır. Bunlardan en önemlisi; tahılın depolanma parametreleri olan sıcaklık ve nem değerlerinin sabit kabul edilerek sadece CO₂ oranına bağlı kalınarak tahılın izlenmesidir. Bununla birlikte mevcut sistem insan gücüne dayalı bir sistem olduğundan verilerin sunucuya ulaştırılmasında hataya ve çok fazla kaybına sebep olabilmektedir. Ayrıca, tahıl torbasının ölçüm ve konum bilgileri teminci firma tarafından da kontrol edildiğinden stratejik öneme sahip ve olağanüstü durumlarda gizli kalması gereken (savaş, doğal afet vb.) stoklara ait konum bilgileri veri güvenliği açısından risk oluşturmaktadır.

Bu çalışmada mevcut Tahıl Kontrol Sistemine ait yukarıda belirtilen hususların yeni tasarlanan Tahıl Kontrol Sistemi ile geliştirilmesi amaçlanmaktadır. Bunun için kablosuz ağlardan faydalanılarak Raspberry Pi 3 cihazı ile sensör düğümleri oluşturulmuştur. Sensör düğümleri vasıtasıyla prototip tahıl torbaları içerisindeki farklı sıcaklık ve nem değerlerine sahip tahılın durumuna ilişkin veriler elde edilebilmektedir. Sensör düğümleri vasıtasıyla elde edilen tahıl depolama parametrelerine ilişkin sıcaklık ve nem değerleri yeni tasarlanan kullanıcı ara yüzü ile sürekli olarak izlenebilmektedir ve veri tabanına kaydedilerek seçilen tarih aralığına göre veriler filtrelenebilmektedir. Veri tabanına kaydedilen veriler ile yapay sinir ağları vasıtasıyla tahılın durumuna ilişkin sınıflandırma yapılarak tahıl Güvenli, Riskli ve Tehlikeli olarak 3 farklı

kategoriye ayrılmıştır. Yapay Sinir Ağları ile tahılın sınıflandırma işlemi Matlab ortamında gerçekleştirilmektedir. Tahılın sınıflandırılmasında Yapay Sinir Ağlarında kullanılan farklı eğitim algoritmaları (Traingdm, Trainlm, Trainscg) ve eğitim ağına ilişkin farklı parametreler (aktivasyon fonksiyonu, çevrim sayısı, nöron sayısı, gizli katman sayısı, vb.) denenerek en iyi sonucu veren değerler tespit edilmiştir. Kullanıcı ara yüzü ile elde edilen ve 3 farklı kategoride sınıflandırılan tahıla ait verilerin kullanıcı tarafından kolaylıkla anlık olarak yorumlanabilmesi ve elde edilen sonuçlara göre gerekli tedbirlerin alınabilmesi amacıyla Matlab kullanıcı ara yüzü (Graphical User Interface-GUI) tasarlanmıştır. Tasarlanan bu sistem ile mevcut sisteme göre doğru sonuçların elde edilerek tahıla gerekli müdahalenin yapılabilmesi, iş gücü ve zaman kaybının en aza indirgenmesi ve veri güvenliğinin arttırılması sağlanmaktadır.

Bu tez çalışması 6 ayrı bölümden oluşmaktadır. İlk 3 bölüm literatür araştırmasını kapsayan genel bilgileri içermektedir. Her bölümün genel içeriği aşağıda özetlenmiştir.

Birinci bölümde, mevcut Tahıl Torbalama Sistemi ve ekipmanları detaylı bir şekilde anlatılmış olup sistemin ekipmanlarından Tahıl Kontrol Sistemine ait problemlere değinilerek bu problemlerin tez çalışması kapsamında nasıl çözüldüğüne yer verilmiştir. Ayrıca tez kapsamında yararlanılan güvenli tahıl depolama özellikleri literatürde geçen çalışmalar ışığında detaylı olarak yine bu bölümde anlatılmıştır.

İkinci bölümde, bu tez çalışmasında kullanılan kablosuz ağ teknolojilerinin özellikle tarımsal uygulamalarda nasıl kullanıldığına literatürde geçen çalışmalar doğrultusunda yer verilmiştir.

Üçüncü bölümde, makine öğrenmesi ve öğrenme stratejilerine genel hatlarıyla yer verilmiş, bununla birlikte bir makine öğrenme tekniği olarak bu tez çalışmasında tahılın sınıflandırılmasında kullanılan Yapay Sinir Ağlarının genel özellikleri ve literatürde yapılan çalışmalar detaylı bir şekilde anlatılmıştır.

Dördüncü bölümde, tez kapsamında tasarlanan Tahıl Kontrol Sisteminde kullanılan kablosuz sensör tasarımlarına ve sistem bileşenlerine detaylı bir şekilde yer verilmiş olup daha sonra bu sistem kapsamında yeni tasarlanan kullanıcı ara yüzü kullanımı detaylı bir şekilde açıklanmıştır. Tahılın sınıflandırılmasında kullanılan 3 farklı sınıfın “Güvenli”, “Riskli” ve “Tehlikeli” tahılın nasıl elde edildiği, bu sınıflara ait verilerin Matlab üzerinden YSA ile eğitilerek sınıflandırılması ve bu sınıflandırmada kullanılacak optimum ortak parametrelerin seçimi ile farklı eğitim algoritmaları

(Traingdm, Trainlm, Trainscg) için YSA durum sınıflandırıcının nasıl oluşturulduğu yine bu bölümde anlatılmıştır. Son olarak da yeni tasarlanan sistem vasıtasıyla anlık olarak okunan ve Matlab vasıtasıyla YSA ile sınıflandırılmış verilerin kolaylıkla yorumlanabilmesi amacıyla Matlab GUI tasarımına yer verilmiştir.

Beşinci bölümde, Tahıl Kontrol Sistemi ile elde edilen 3 farklı sınıfa (Güvenli, Riskli ve Tehlikeli) ait tahılın sıcaklık ve nem verilerine ait grafikler gösterilmiştir. Bununla birlikte Matlab ortamında eğitim veri tabanı üzerinde farklı eğitim algoritması (Traingdm, Trainlm, Trainscg) için YSA kullanılarak elde edilen ağların performans grafiklerine, bu ağların test veri tabanı üzerinde denenmesi ile en iyi performansı gösteren eğitim algoritmasının başarımlar oranı grafiğine ve eğitim algoritmaları karşılaştırma tablosuna yine bu bölümde yer verilmiştir.

Tezin son bölümünde de bu tez çalışması neticesinde tasarlanan yeni Tahıl Kontrol Sisteminin mevcut sisteme göre üstünlüklerinden bahsedilmiştir. Ayrıca tasarlanan Tahıl Kontrol Sisteminin geliştirilerek gelecekteki tarımsal uygulamalardaki farklı çalışmalara nasıl ışık tutabileceğine, mevcut kapalı depo (silo, yatay depo, vb.) sistemleri üzerindeki kullanılabilirliğine yer verilmiştir.


1. BÖLÜM

MEVCUT TAHIL TORBALAMA SİSTEMİ, PROBLEMLERİ VE GÜVENLİ TAHIL DEPOLAMA

1.1. Mevcut Tahıl Torbalama Sistemi

Tahıl depolama sistemlerinde tahıl kalitesini uzun vadede koruyabilmek, hem tüketiciler için hem de tahıldan kâr sağlayan üretici için önemli bir unsurdur. Bu kapsamda Türkiye’de başta hububat olmak üzere tarımsal faaliyet alanındaki ürün piyasalarını düzenleme görevi Toprak Mahsulleri Ofisi (TMO) tarafından Türkiye genelinde çeşitli tonaj ve tiplerde kapalı depo ile yürütülmektedir. Kapalı depo kapasitesinin Türkiye genelinde yetersiz kaldığı durumlarda tahıl ürünleri toprak altında açık yığınlar da depolanmaktadır. Geleneksel yöntemlerle açık yığınlar da yapılan depolamaya alternatif olarak TMO tarafından 2014 yılında Tahıl Torbalama (Silobag) Sistemi geçişine öncülük edilmiştir. Bu sistemle, açık yığınlar da sel, kemirgen tahribatı vb. nedenlerle meydana gelen ürün kayıplarının azaltılması amaçlanmaktadır. Buna ek olarak bu sistemle işçilik ve zaman kayıplarının açık yığınlara oranla azaltılarak ürünlerin daha uygun ve modern şartlar da depolanması sağlanacaktır [4].

Tahıl depolamada kullanılması için Arjantin’de geliştirilen Tahıl Torbalama sistemi hermetik bir depolama yöntemi olup genel olarak yükleme, torbalama, boşaltma ve depolanan tahılın izlenmesi kısımlarından oluşmaktadır. Bu kısımlar kendine özgü donanım ve sistemler içermektedir. Tahıl Torbalama Sisteminde kullanılan bu donanım ve sistemlerin şematik gösterimi Şekil 1.1’de gösterilmiştir:



Şekil 1. 1. Tahıl Torbalama Sistemi

Tahıl Torbalama Sisteminin ekipmanlarından tahılın depolandığı tahıl torbası en az 60 metre uzunluğunda, 235 mikron kalınlığında, 2,74 metre çapında ve tüp şeklinde lamine plastik malzemeden oluşan torbalardır. Şekil 1.2’de gösterilmektedir. Plastik tahıl torbaları % 10’luk esneme payına sahip olup UV ışınlarına, hava ve suya karşı dayanıklı içi siyah dışı beyaz katmandan oluşmakta olup her biri ortalama 200 ton tahıl depolama kapasitesine sahiptir [5].




Şekil 1. 2. Tahıl Depolama Torbası

1.1.1. Tahıl Kontrol Sistemi

Tahıl Torbalama Sisteminde belirli periyotlarda tahıldaki CO₂ oranının ölçülerek elde edilen verilerin kullanıcı bilgisayarı veri tabanına kaydedildiği, buradan da Arjantin'deki merkezi sunucuya iletilerek, tahılın durumu hakkında yorum yapabilen halihazırda kullanılan mevcut Tahıl Kontrol Sistemidir. Mevcut Tahıl Kontrol Sisteminin temel amacı CO₂ ölçüm teknolojisi ile modern veri transferi ve işleme teknolojileri kullanılarak tahıl torbaları için bir izleme sisteme sağlayabilmektir. Bu mevcut sistemi hakkında yapılan çalışmalar neticesinde tek başına CO₂ oranının izlenmesinin tahılın uzun süre bozulmadan depolanabilmesi için yeterli bir parametre olduğu belirlenmiştir ve Tahıl Torbalama Sisteminin mevcut kontrol ünitesinde CO₂ parametresini izlemeye yönelik bir sistem geliştirilmiştir [6].

Mevcut tahıl torbası kontrol sistemi CO₂ ölçüm cihazı ve RFID etiketinden oluşmaktadır. RFID etiketi, istenilen tahıl ile dolumu tamamlanan her bir torbaya özgü olarak iliştilir. Bunun yanında tahıl torbasına 6 metre aralıklarla ölçüm noktaları yapıştırılır [7]. Şekil 1.3'de bu durum gösterilmektedir.



Şekil 1. 3. Ölçüm Noktaları ve RFID Etiketinin Şematik Gösterimi

RFID etiketinin tahıl torbası üzerine yapıştırılmasından sonra etiket çevrimiçi veri tabanı üzerinden aktive edilerek tahıl torbası ile ilgili bilgiler sisteme yüklenir. Bu bilgiler içerisinde konum(bölge, çiftlik, ve coğrafi koordinatlar), mülkiyet(tahılın sahibi, telefon ve faks numarası, e-posta adresi) ve tahıl bilgileri (torbalanma tarihi, tahılın çeşidi, nem içeriği ve kalite) yer almaktadır [7].

Mevcut Tahıl Kontrol Sisteminin bir diğer ekipmanı olan CO₂ ölçüm cihazı ise kızılötesi (infrared) teknolojiye sahip CO₂ sensörü, tahıl torbasının içindeki havayı çekerek sensöre ulaştırmaya yarayan pompa, hava iletimini sağlayan plastik boru ve borunun ucundaki iğneden oluşmaktadır. Şekil 1.4'te gösterilmektedir. Cihaz üzerinde tahıl torbasında açıklıklar (delinme, yanlış mühürleme, kemirgen tahribatı, vb.) ile tahıl


torbasının etrafındaki ve altındaki toprağın sele maruz kalması sonucu bataklık haline gelmesi (soil flooding) durumunda operatör tarafından sunucuya bilgi verebilmek için butonlar da yer almaktadır. Ayrıca ölçüm cihazında batarya, veri depolama sistemi, GPS, RFID okuyucu ve GPRS sistemi ile veri transferini sağlayan iletişim modülü bulunmaktadır [7].



Şekil 1. 4. CO₂ Ölçüm Cihazı


CO₂ Ölçüm Cihazı ile toplanan veriler merkezdeki sunucuya (server) GPRS teknolojisiyle veya verilerin USB port aracılığıyla bilgisayara yüklenmesinin ardından gönderilmektedir. Daha sonra merkez sunucuya CO₂ oranıyla ilgili gelen veriler, tahılın depolanma koşullarıyla ilgili önceki araştırma verileriyle hazırlanmış referans grafik ile kıyaslanarak depolanmış tahılın güncel durumu yorumlanır. Bu yorumlama yapılırken tahıl torbasının ilk etiketlemedeki tahıl tanecik suyu oranı, konum (ortalama çevre sıcaklığı), depolanma zamanı, önceki CO₂ verileri, torbanın yırtık olup olmaması gibi parametreler de dikkate alınır [7].

Son olarak tüm bu veriler ve parametreler ışığında tahıl güvenli, riskli, tehlikeli olarak 3 ayrı kısımda sınıflandırılır [7]. Şekil 1.5'te bu durum gösterilmektedir.



Şekil 1. 5. Tahıl Tanecik Suyu Oranı ve CO₂ Ölçümüne Bağlı Referans Grafiği

Yorumlanan bu bilgilerin kullanıcıya ulaştırılmasında ve gerekli önlemlerin alınmasında web üzerinden izleme sistemi kullanılmaktadır. Şekil 1.6'da web izleme sisteminin ana menü ekran görüntüsü yer almaktadır. Bu sistem ile kullanıcı depolanan tahılın güncel durumu (riskli, tehlikeli, güvenli) hakkında bilgi sahibi olabilmekte, bunun yanında müşteri bilgileri (isim, adres, iletişim vb.), tahılın cinsi, tahıl nem içeriği, depolanma zamanı, torbanın konumu gibi birçok bilgiye erişebilmektedir [7].



Şekil 1. 6. Web İzleme Sistemi Ana Menü Ekran Görüntüsü

Şekil Mevcut Tahıl Kontrol Sistemi yukarıda da bahsedildiği gibi, periyodik olarak karbondioksit oranının izlenmesi metoduyla depolanan tahılın güncel durumu hakkında bilgi edinme olanağı sağlayarak tahıl torbası içindeki mikroorganizmaların ve haşerelerin biyolojik aktivitelerinin ile bozulan tahılın erken tespitine yönelik olarak tasarlanmıştır.

1.2. Mevcut Tahıl Torbalama Sisteminin Problemleri

Bu çalışma kapsamında mevcut Tahıl Torbalama Sisteminin kısımlarından Tahıl Kontrol Sisteminin problemleri incelenmiştir. Bu kapsamda mevcut sistemin incelenmesi ve kullanıcıların geri bildirimleri doğrultusunda sisteme ait tespit edilen problemler ve bu problemlerin çözümüne yönelik bu tezde yapılan çalışmalar aşağıda yer almaktadır:

- Mevcut sistemde sadece CO₂ ölçümleri periyodik olarak yapılmakta, tahılın kalitesinde önemli bir etken olan nem oranı yalnızca tahılın depolanma anında ölçülerek sabit bir parametre olarak kabul edilmektedir. Ayrıca tahılın bozulmasının tespitinde önemli bir etken olan sıcaklık faktörü konum bilgilerine bağlı olarak o bölgenin ortalama dış çevre sıcaklığı dikkate alınarak sabit bir parametre olarak sisteme kaydedilmektedir. Referans grafiğinde de değerlendirmeler, sabit nem oranına bağlı değişken CO₂ oranına göre yapılmaktadır. Ancak, tahıl torbası açıklıkları (delinme, yanlış mühürleme, kemirgen tahribatı, vb.) ile tahıl torbasının etrafındaki ve altındaki toprağın sele maruz kalması sonucu bataklık haline gelmesi (soil flooding), tahıl torbası içindeki nem oranını değiştiren önemli unsurlardır. Problemin çözümü olarak, bu tez çalışmasında Tahıl Kontrol Sisteminde doğru sonuçlar elde edilebilmesi ve bozulan tahılın erken tespitinde tahıl nem ve sıcaklığın değişken bir parametre olarak değerlendirilerek periyodik nem ve sıcaklık ölçümünün yapılabilirdiği bir sistem geliştirilmiştir.
- Tahıl torbalarının herhangi bir bölgede çok sayıda olduğu durumlarda bu ölçüm yönteminin aşırı miktarda iş gücü gerektirmesi ve verilerin sunucuya ulaştırılmasında zaman kaybına neden olması kaçınılmazdır. Ayrıca verilerin aktarılması insana dayalı bir sistem olduğu için hata yapma olasılığı fazladır. Örnek olarak; operatör ölçüm alırken torbada oluşmuş deliği fark edemeyerek cihaz üzerindeki butona basmaksızın verileri sunucuya gönderebilir. Problemin çözümünde, bu tez çalışmasında kablosuz ağlar kullanılarak iş gücünden arındırılmış ve insan odaklı hataların en aza indirildiği bir sistem tasarlanmıştır.
- Mevcut Tahıl Kontrol Sisteminde tahıla ait CO₂ konsantrasyon ölçüm verilerinin yanı sıra torbalama esnasında tahıl torbalarına ait konum bilgileri de merkezi kontrolü Arjantin’de bulunan teminci firmaya ait sunucuya yorumlanması için gönderilmektedir. Gönderilen bu bilgiler, TMO’nun stratejik öneme sahip stoklarının bulunduğu tahıl torbalarına ait konum bilgilerini içerebilir. Bu nedenle söz konusu verilerin sadece tahıl torbası sahibinin izleyebileceği bir sistemle kontrol edilmesi veri güvenliği açısından büyük önem taşımaktadır. Bu problemin çözümünde ise, izlenmesi yabancı bir ülke tarafından yapılan bu

sistem yerine tahıl stoklarının sadece Kurumun yetkili kişilerince izlenebileceği ve dışa bağımlılık gerektirmeyen güvenli ve yerli bir sistem tasarlanmıştır.

1.3. Güvenli Tahıl Depolama

Gıda maddelerinin ister bitkisel ister hayvansal kaynaklı olsun uzun süre bekletilmeleri halinde, yapıları gereği bazı değişikliklere uğramaktadırlar. Dolayısıyla, gıdaların ve gıda hammaddelerinin bozulmadan, özelliklerini kaybetmeden saklanabilmeleri, başka bir deyişle depolanmaları oldukça önem kazanmaktadır [8].

Depolamanın amacı, ürünün özelliklerini ve tazeliğini belirlenen bir amaçla değerlendirilinceye kadar korumaktır. Depolamada, ürünün canlılık gücü kaybının en alt seviyede tutulması amaçlanmaktadır [9,10,11].

Tarımsal ürünlerde yapısal bozulma, filizlenme, ısınma, haşere zararları nedeniyle her yıl hasat, taşınma ve depolama sırasında büyük ölçüde maddi kayıplar ortaya çıkmaktadır. Depolama süresince oluşan bozulmalar ve kayıplar, ancak uygun depolama koşulları ve depolama yönetimi ile azaltılabilmesi mümkün olmaktadır [12].

Tahılın canlılığını koruyabilmesi ve en yavaşlatılmış şekli ile canlılığını sürdürebilmesi için enerjiye ihtiyaç duymaktadır [8]. Bu nedenle tahıl canlılığını devam ettirebilmek için, hasat edildikten sonra da solunum yapmaktadır. Solunum tahıldaki bileşenlerin atmosferik oksidasyonla karbondioksit dönüşümüdür. Bu solunum olayı sırasında tahılın yapısındaki maddelerden özellikle karbonhidratlar parçalanarak su ve ısı açığa çıkmaktadır [13].

Tahılın solunumu sonucunda ortaya çıkan su ve ısı, depolanan ürünü olumsuz yönde etkileyerek, tahılda kızışmaya sebep olmaktadır [13]. Kızışma tahıl kitlesindeki nem içeriğinin ve sıcaklığının artması durumudur. Soğutma ve havalandırma tahıl depolarında yeterli olmadığı takdirde, depolanan ürün zamanla kendiliğinden ısınarak büyük çapta hasar ve kayıplara neden olmaktadır [14].

Depolanan ürünün sıcaklık ve nem içeriği, ürünlerin solunum miktarını ve dolayısıyla depolama sürecinde meydana gelebilecek bozulma ile kayıpları etkileyen en önemli faktördür. Sıcaklık ve nemin gerek ayrı ayrı gerekse birlikte etkileri ürünlerde büyük maddi kayıplara yol açmaktadır. ABD’de yürütülmüş bir araştırmada, hububat ve kuru otun hasat ve depolanması sırasında oluşan kayıpların yıllık tutarının 1,25 milyar \$ civarında olduğu belirlenmiştir [14]. Bu araştırmadan da anlaşılacağı üzere depolama

sürecinde meydana gelen bu kayıpların önlenmesi için uygun depolama koşullarının sağlanması ve depo yönetimi çok önemlidir.

Sıcaklık ve nemin uygun düzeyde tutulması, depolama kayıplarının azaltılmasında önemli bir rol oynar. Her ne kadar bu durum ürün çeşidine göre farklılık gösterse de uygun şartlar sağlanmadan yapılan depolamalarda ürün kayıplarının önlenmesi düşünülemez [14].

Tarımsal ürünlerin ve mikroorganizmaların solunum hızı düşük sıcaklık ve nem değerlerine doğru orantılı olarak düşmektedir. Örneğin, buğdayın 30 °C sıcaklık ve % 16 nem içeriğindeki solunum hızı, %12 nem içeriğindeki solunum hızından birkaç yüz kat daha fazla, %30 nem içeriğine sahip buğdayın solunum hızı ise %16 nem içeriğindeki buğdaya göre birkaç bin kat daha fazladır [15]. Solunum hızının düşmesi, yani sıcaklık ve nem artışının engellenmesi, tahılda yapısal bozulmaların, küf gelişiminin ve böcek aktivitesinin azaltılmasını sağlayarak ürünün ömrünü arttırmaktadır [16].

Depolama sıcaklığı arttıkça ürünün nemi de artmaktadır. Tahılın sıcaklığı 10 °C'den 25 °C'ye yükselmesi halinde nem içeriğinin %1 oranında arttığı tespit edilmiştir [17]. Ürünün nemi özellikle %20'nin üzerine çıktığında solunum hızlanmakta ve tohumun yanmasına neden olacak kadar yüksek bir ısı ortaya çıkararak üründe oluşan kayıplar artmaktadır [18].

Ürünün nemindeki artış, tohumun dış etkilerle kırılmasını ve zedelenmesini arttırmaktadır. Özellikle zedelenmeler, nem içeriği %18-20 arasında olduğunda en üst düzeyde ortaya çıkmaktadır. Kırık ve zedelenmiş taneler sağlam tanelere göre 3-4 kat daha hızlı bozulmakta ve zararlı mikroorganizma ve haşereler bu tahıllardan daha kolay beslenebilmektedir [10]. Oklahoma'da yapılan bir araştırmada, depolanan tahıllarda küf ve böceklerin yarattığı yıllık kayıpların %10 olduğu belirlenmiştir [19].

İyi muhafaza edilmeyen tahıllar; böceklenme, küflenme, kızışma, embriyo zedelenmesi, çimlenme gücü kaybı ve çürüme gibi zararlara uğrayabilir. Tane nemi depolanma süresince yükselmeye başladıkça çevre atmosferinin nispi nemi %85'e kadar yükselebilir ve bu durumda küf mantarlarının aktivitesi daha da artar. Solunum hızlanır, yığında hızla bir sıcaklık yükselmesi gözlenir, sonuçta sıcaklığın yükseldiği bölgelerde, küf kokulu, koyu kahve renkte yanık taneler oluşur ki, bu olgu "Silo yanığı" veya "Ambar yanığı" olarak tanımlanır [20].

Küf gelişimi; sıcaklık, nispi nem ve oksijen içeriği gibi depo şartlarına ve tane suyu içeriğine bağlıdır. Tane suyunun kritik depolama su içeriği olan %14 değerini aşmasının ardından artan sıcaklıkla birlikte depolama ortamındaki küf faaliyeti de artmaktadır. İlk önce su damlacıklarının bulunduğu yerlerde başlayan küf faaliyeti, mekanik bütünlüğünü kaybetmiş tanelerde ve tanelerin embriyo kısımlarında devam etmektedir [21].

Güvenli bir depolama için tahılların nem içeriğinin düşürülmesi, ürünün besleyicilik değerinde artış sağlar. Nem içeriği (tanecik suyu) yüksek taneler düşük olanlara göre bakteri ve küflerin üremesi için daha uygundur. Güvenli bir depolama için en yüksek nem içeriği (tanecik suyu); buğdayda %14, mısırdaki, arpada, yulafta %13, pirinçte ise %12-13 olmalıdır [22]. Eğer tahılların nem içerikleri bu değerlerden yüksek ise tahıllar depolamadan önce kurutularak ve/veya havalandırılarak nem içerikleri güvenli depolanabilecekleri uygun sınırlara getirilmelidir [23].

Tane suyu içeriği depolamanın güvenli bir şekilde yapılabilmesi için kontrol altında tutulması gereken en önemli faktördür. Güvenli tahıl depolamada; tane suyu içeriği %14'ten ve depo nispi nemi %65'den düşük olmalıdır [24].

Depo nispi neminin %65'den daha yüksek değerlerde olması halinde, tahıl tanelerinin su içeriklerinin, tahılın higroskopik (neme karşı duyarlı olan) özelliği nedeniyle, %14 değerinin üzerine çıktığı ve bozulmanın hızlandığı tespit edilmiştir. Dolayısıyla sağlam taneli tahılların iyi bir şekilde depolanabilmesi için alınacak temel önlemler; tane su içeriğini %14 ve depo nispi nemini ise %65 değerleri altında kalmasını sağlamaktır. Yine bu iki faktörün sıcaklıktan hızlı bir şekilde etkilenmeleri nedeniyle tahıl depolamada, depo sıcaklığının da iyi bir şekilde kontrol altında tutulması gerekmektedir [24].

Sonuç olarak; iyi bir tahıl depolama işlemi için, tahıl deposunda birbirlerini etkileyen; solunum, yığın sıcaklığı, tane suyu ve depo nispi nemi gibi faktörlerin kontrol altında tutulması gerekir. Bu faktörler depo içerisindeki tahılın kendi solunum faaliyetinin yanı sıra mikroorganizma ve haşere faaliyetiyle birlikte atmosferik şartlardan da etkilenmektedir. Dolayısıyla, ekonomik kayıp ve sağlık risklerinin oluşmasını engellemek için; tahılların depolanmadan önce bir ön temizleme işleminin sağlanması, depolama sürecinde ise tane suyu içeriğinin %14, yığın sıcaklığının 25°C ve depo içi nispi neminin %65 değerlerinin altında tutulması gerekir [24].

2.BÖLÜM

TARIMSAL UYGULAMALARDA KABLOSUZ HABERLEŞME TEKNOLOJİLERİ

2.1. Kablosuz Haberleşme Teknolojisi


Çağımız teknolojisinde yere ve zamana bağlı kalmaksızın haberleşebilmek insanların vazgeçilmez ihtiyaçlarından biri olmuştur. Bu noktada kablo ile fiziksel bağlantı yapma zorunluğu olmadan özgürce çalışabilme imkanının olmasının yanı sıra, kablolu sistemlerde fazla enerjiye ihtiyaç duyulması ve kullanılan donanımsal ekipmanların büyüklüğü gibi etmenler kablosuz haberleşme teknolojilerinin kullanımını kaçınılmaz kılmıştır. Kablosuz haberleşme, kablolu iletişim kaynaklı problemleri minimuma indirmek için verilerin elektromanyetik dalgalarla havadan iletildiği esnek ve hareketli bir iletişim teknolojisidir [25]. Günümüz teknolojik gelişmeleri ile birlikte kablosuz haberleşme düşük maliyetli, enerji tüketimi az olan çeşitli fonksiyonlara sahip dış çevreyi algılayan, veri toplayan ve bu verileri işleyebilen sensör düğüm noktalarının geliştirilmesine imkan tanımaktadır [27].

2.2. Literatürdeki Tarımsal Uygulamalarda Kablosuz Haberleşme Teknolojileri

Kablosuz haberleşme teknolojilerinde son yıllarda yaşanan hızlı gelişmelerin tarımsal faaliyetlerde de uygulanması; özellikle insan iş gücünün azaltılması, çiftçi refahının sağlanması, üretimin daha verimli ve kaliteli yapılması açısından kaçınılmaz olmuştur [26]. Tarımda kullanılan kablosuz sensör ağ uygulamalarına örnek olarak; iklimsel izleme, hassas tarım uygulamaları (mekansal veri toplama, hassas sulama uygulamaları, üreticilere veri tedariki, vb.), makine ve süreç kontrolü, tesis otomasyonu verilebilir [25].

Kablosuz Sensör Ağları ile iklim koşullarını uzaktan izleyebilmek için kablosuz örgü ağı (wireless mesh network) sistemi Ayala ve arkadaşları tarafından geliştirilmiştir [28]. Uzun menzilli olan kablosuz örgü ağı sistemi üç ana elemandan oluşmaktadır. Bu elemanlar uzaktan bağlantı ünitesi (Remote

Terminal Unit-RTU), ana bağlantı ünitesi (Base Terminal Unit-BTU) ve ana sunucudan (Central Server-CS) oluşmaktadır. RTU'lar yüksek performanslı mikrodenetleyicileri ve meteorolojik sensörleri ile iklimsel değişkenleri (hava sıcaklığı, bağıl nem, barmotrik basınç, solar radyasyon, rüzgar yönü, rüzgar hızı, yağmur) izlemek için tasarlanmıştır. Her bir RTU diğer bir RTU ile etkileşim halinde olup kablosuz yerel alan ağı (Wireless Local Area Network-WLAN) oluşturmaktadırlar. RTU'lar sensörler vasıtasıyla elde ettikleri verileri 900 MHz frekansla ISM (Industrial Scientific Medical) bandı üzerinden BTU'ya aktarmaktadır. ISM bandı üzerinden 64 km mesafeye kadar uzaktan bağlantı ünitesi ile nokta-nokta haberleşmesi sağlanmaktadır [28]. Ağ içindeki trafiği kontrol ederek uydu bağlantısı ana bağlantı ünitesi tarafından gerçekleştirilmektedir. BTU'dan merkezi sunucuya Ku haberleşme bandı üzerinden gönderilen veriler kullanıcıya Web portalı üzerinden grafiksel ara yüz vasıtasıyla ulaştırılmaktadır. Şekil 2.1'de sisteme ait şematik gösterim yer almaktadır.



Şekil 2. 1. Kablosuz Sensör Ağları ile İklim Koşullarının İzlenmesi [28]

Patates tarımında Shingal ve arkadaşları kurdukları sistem ile sulama verimliliğini arttırmışlardır [29]. Geliştirilen sulama yönetim modelinde hesaplanan su derinliği, toprak su tansiyonu ve sistem kapasitesi gibi tarımsal parametreler kablosuz ağların kullanılmasıyla en iyi verimi sağlamak ve optimum seviyede toprak tansiyonunu korumak ve sulama etkinliğini arttırmak için tahmin edilmiştir.

Hayvansal üretimde ve seracılıkta sulama planlaması, erişim kontrolü, yapısal izleme, aydınlatma kontrolü, enerji yönetimi gibi işlemlerde kablolu teknolojilerin yıllardır kullanımda olmasının yanı sıra kablosuz teknolojilerde son yıllarda hızla geliştirilerek pazara sunulmuştur [25].

Bitkilere ait sıcaklık, nem, elektriksel geçirgenlik, günlük fotosentetik radyasyon ve yaprak ıslaklığını anlık olarak ölçmek üzere Lea-Cox ve arkadaşları tarafından kablosuz sensör ağı tasarlanmıştır [30]. Bu sistem daha etkin su ve gübre kullanımı, aşırı sulama kaynaklı hastalık problemlerinde azalma ve iyileştirilmiş bitki gelişimi şeklinde yarar sağlamaktadır.

Portekiz’de kurulu olan seralar için iç ve dış ortam iklim verilerini kaydetmek amacıyla Morais ve arkadaşları tarafından kablosuz veri iletim ağı kurulmuştur [31]. Güneş enerjisi ile çalışan birçok veri toplama istasyonu iç ve dış ortamlara ait iklim verilerini ölçmek ve izlemek amacıyla yerleştirilmiştir. Bu veri toplama istasyonlarıyla ofis bilgisayarları arasında kablosuz ağlar ile bağlantı kurularak hem istasyonlar gözlemlenmiş hem de veriler kayıt edilmiştir.

Ulaşım, Sağlık ve Güvenlik gibi sektörlerde yaygın bir şekilde kullanılan makine odaklı haberleşme tarım sektöründe de kullanımı hızlı bir şekilde artmaktadır. Makineler arasında insan müdahalesi olmaksızın ya da çok sınırlı insan müdahalesi bulunan haberleşme şekli olarak genel çerçevesi çizilen makine odaklı haberleşme haberleşme sektöründe “makineler arası haberleşme” (machine to machine communications-M2M) kavramı ile ifade edilmektedir. Bu tanımlamada yer alan “makine” ise aslında, haberleşme kabiliyeti bulunan veya kazandırılan bir cihaz veya ekipman olabilmektedir [32]. Makine öğrenme teknolojileri kapsamında; narenciye ve zeytin bahçelerinde ilaçlama işlerinde kullanılmak üzere Ribeiro ve arkadaşları tarafından otonom bir traktör geliştirilmiştir [33]. İnsansız olarak kullanılan bu traktörlerin kablosuz bir şekilde uzaktan izlenerek kontrol edilebilmesi için kullanıcı dostu görsel bir araç geliştirilmiştir.

Dayıoğlu ve arkadaşları nesnelerin interneti teknolojisi ile sera içindeki sıcaklık değişimlerinin ölçülmesi, kablosuz olarak web ortamına aktarılması ve izlenmesi amacıyla prototip bir sistem geliştirmiştir [34]. Sıcaklık ölçümü için internete bağlanabilen iki adet kablosuz sensör düğümü tasarlanmıştır. Her bir sensör düğümü Raspberry Pi tek kart bilgisayar, Wifi Adaptörü ve 2 adet sıcaklık sensöründen oluşmaktadır. Bu çalışmada tek bir sensör düğümünün aynı zamanda sunucu bilgisayarı olarak da yapılandırılmasına olanak sağlamaktadır. Sensör düğümlerinin çalışma ayarları web ara yüzü üzerinden değiştirilebilmektedir. Düğümlerdeki entegre web sunucusu vasıtasıyla sistem internet bağlantısı olmadan da intranet üzerinden kullanılabilir. Bu sistem ile sera içinde ölçülen hava, toprak ve su sıcaklığı verileri Web ortamında sürekli olarak izlenmekte ve elde edilen veriler veri tabanına kaydedilmektedir.

Yukarıda bahsedilen literatür araştırması doğrultusunda bu çalışmada kablosuz ağ teknolojilerinden faydalanılarak kablosuz sensör düğümü tasarımı yapılmıştır. Kablosuz sensör düğümleri yardımı ile prototip tahıl torbası içerisindeki tahıla ait sıcaklık ve nem değerleri ölçülerek kullanıcı ara yüzüne aktarılmaktadır.

Bir sonraki bölümde de yine tez çalışmasında faydalanılan ve bir makine öğrenme tekniği olan yapay sinir ağlarından, yapay sinir ağları ile sınıflandırmadan ve makine öğrenmesi tekniklerinden literatürde yapılan araştırmalar kapsamında bahsedilmiştir.

3.BÖLÜM

MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI İLE SINIFLANDIRMA

3.1. Makine Öğrenmesi ve Öğrenme Stratejileri

Bu bölümde özetle; tez çalışmasında tahılın sınıflandırılmasında kullanılacak bir makine öğrenmesi tekniği olan yapay sinir ağlarından ve literatürde yapay sinir ağları ile sınıflandırma kapsamında yapılan çalışmalardan bahsedilecektir. Yapay Sinir ağlarından önce ilk olarak makine öğrenmesinin ne olduğu ve makine öğrenme (machine learning) teknikleri detaylarıyla açıklanacaktır.

Makine öğrenmesini anlayabilmek için öncelikle *öğrenme* kavramının tanımlanması gerekmektedir. Öğrenme kavramı değişik şekillerde tamamlanabilmektedir. Türk Dil Kurumuna göre öğrenme, yetenek, bilgi ve düşünme tarzı kazanımı anlamlarında kullanılmaktadır. Bununla birlikte öğrenme, eğitim ile beraber, deneyim edinerek ve çalışarak tavır ve davranışlarda ortaya çıkan sürekli bir değişimdir.(Online Business Dictionary, 2018). Simon ise öğrenmeyi, “bilgilerin keşfedilmesi yoluyla davranışların zaman içerisinde iyileştirilmesi süreci” olarak tanımlamaktadır [35].

Bir insan yerine bir makinenin öğrenebileceğini düşünmek ilk izlenime göre zor olsa da, makinelerin öğrenmesi matematik, istatistik ve yapay zeka bilimlerinin işbirlikçi çalışmaları sonucu mümkün kılınmıştır. Birçok insan için “Makine”, çelik donanımlara, dişlilere, motorlara çağrışım yapsa da, çağımızda bilgisayarların da bir makine olabileceği anlayışı büyük oranda yaygınlaşmıştır; şöyle ki yazılım ve donanım sistemlerinden oluşan bilgisayarın yazılım sistemi bir makine olarak düşünülmektedir [36]. Bu doğrultuda, cep telefonu, çamaşır makinesi, televizyon gibi bir makinenin öğrenmesini sağlayan başlıca etmenin içlerinde bulunan bilgisayar programları olduğunu söylemek mümkündür. *Makine öğrenmesi* olarak dilimize yerleşen bu

kavram yapay öğrenme şeklinde de ifade edilmektedir [38]. Diğer bir deyişle makine öğrenmesi; bilgisayarın bir olay ile ilgili bilgileri ve tecrübeleri öğrenerek gelecekte oluşacak benzer olaylar hakkında kararlar verebilmesi ve problemlere çözümler üretebilmesidir. Bilgisayarın öğrenebilmesi ve tecrübe sahibi olabilmesi bilgisayarın ilgili olay hakkında bilgiler ile donatılmasına bağlıdır [38].

Alpaydın makine öğrenmesinin maksadını açıklarken çeşitli değişkenlere göre meydana getirilmiş bir prototipi ya da tecrübeler ile bu prototipin başarısının ölçülebildiği bir başarı ölçütü göz önünde bulundurularak, prototipin öğrenme sürecinde en iyi performansı gösterdiği değişkenin bulunması olduğu şeklinde belirtmiştir [37]. Oluşturulan prototip, geleceğe yönelik karar verebilen tahmin etme becerisine sahip veya çıkarım yapmak için kullanılan izah edici bir model olabileceğinin altını çizmiştir. Bir yapay bilimi (artificial science) olan makine öğrenmesindeki temel başarı ölçütünün tecrübeler ve bu tecrübeler doğrultusunda geliştirilen insan yapımı algoritmalar olduğu Langley tarafından vurgulanmıştır [39].

Başarılı bir şekilde tahmin yapabilen algoritmaların tasarlanması makine öğrenmesini meydana getirmektedir [40]. Yani, makine öğrenmesi tecrübe ile gelişen bilgisayar programlarının nasıl oluşturulabileceği ile ilgilenmektedir [41]. Başka bir deyişle makine öğrenmesi, etkin bir şekilde performans iyileştirilmesi yapabilmek amacıyla örnek veri ya da tecrübeleri kullanarak bilgisayar programlamaktır [42]. Bir makinenin verimi deneyimleri ile arttığında, o makine öğrenmiş olarak kabul edilmektedir ve makine öğrenmesi tecrübeler sonucu elde edilen faydalı bilgiyi kaydeden ve gerektiğinde kullanılabilen programlar olmadan düşünülemez [43]. Makine öğrenmesi, değişikliklere uyum sağlayabilen, deneyimlerle duruma veya olaya ait bilgi edinebilen ve elde edilen deneyimlerle başarısını arttıran programları geliştirmekle ilgilenmektedir [44]. Makine öğrenmesi en sade şekliyle tecrübelerle dayanarak ileriye görmektir [45].


Yukarıdaki bilgiler doğrultusunda, Makine öğrenmesiyle ilgili önemli görülen konular, şu şekilde özetlenebilir:

- Öğrenmeyi gerçekleştiren makineler olarak bilgisayarlar düşünülebilir.
- Yukarıdaki makine öğrenmesi tanımlarında bilhassa başarı oranının (performansın) ve deneyimin üzerinde durulması göze çarpan bir husustur.

- Makine öğrenmesinde tecrübe olarak görülen aslında gerekli bilgi ve bu bilginin büyüklüğüdür.
- Makine öğrenme süreci sonunda modelin performansı belirli kıstaslar sayesinde değerlendirilmektedir [46].

Optik karakter algılama, yüz tanıma, önemsiz e-posta filtrelemesi, konuşma dili anlama, tıbbî teşhis, müşteri segmentasyonu, sahtekârlık tespiti ve hava durumu tahmini gibi birçok farklı problemin çözümünde makine öğrenmesi kullanılmaktadır [47].

Makine öğrenmesi ile bir problemin çözülebilmesi için bazı adımların takip edilmesi gerekmektedir. Bu adımlar literatürde geçen ve makine öğrenmesinde kullanılan farklı öğrenme stratejilerine göre farklılıklar göstermektedir. Camastra ve Vinciarelli, makine öğrenmesinde başlıca iki unsur olduğunu belirtmiştir [48]: verilen görevin yerine getirilebilmesi için gerekli bilgiye sahip olan eğitmen, verilen görevin yerine getirilebilmesi için bilgiyi öğrenmek zorunda olan öğrenen. Camastra ve Vinciarelli, öğrenme yöntemlerinin eğitmenden sağlanan bilgiye göre yapılabileceğini belirtmişler ve bu yöntemler Şekil 3.1’de gösterilmiştir:




Şekil 3. 1. Öğrenme Stratejilerinin Sınıflandırılması [48]

Brownlee, öğrenme şekillerini danışmanlı, danışmansız ve yarı-danışmanlı öğrenme olarak üç bölümde incelemiştir [49]. Literatürdeki farklı öğrenme stratejilerine karşın öğrenme biçimlerinin danışmanlı ve danışmansız öğrenme olarak genel olarak ikiye ayrıldığı belirlenmiştir. [43,50,51,52].

Literatürde adı geçen başlıca öğrenme stratejilerine aşağıda kısaca değinilmiştir.

- **Ezberleme Yoluyla Öğrenme:** Bu öğrenme şeklinde yeni bilgi doğrudan öğrenene aktarılmaktadır [48]. Bu sebeple öğrenen tarafından gerçekleştirilmesi beklenen herhangi bir çıkarım söz konusu değildir. Bu öğrenme modeline örnek olarak klasik yollar ile bilgisayarların programlanması ve basit veri tabanı sistemleri verilmiştir.
- **Talimatlar Yoluyla Öğrenme:** Bu öğrenme stratejisinde bilgi bir eğitmen ya da farklı bir kaynaktan gelmekte olup, öğrenen bu bilgiyi girdi dilinden farklı bir iç dile dönüştürebilmektedir. Bu öğrenme biçiminde fazla olmasa da öğrenen tarafından gerçekleştirilen bir çıkarım söz konusudur [48].
- **Benzetimden Öğrenme:** Bu strateji var olan, yeni bir kavram ya da yetenekle benzerlik gösteren bilginin artırılarak ve dönüştürülerek yeni gerçeklere ya da yeteneklere ulaşılmasıdır [48]. Öğrenen tarafından bu öğrenmede yapılan çıkarım, talimatlı ve ezbere dayalı öğrenmeye göre daha fazladır.
- **Danışmanlı Öğrenme:** Bu öğrenme şekli, eğitim verisi olarak alınan bir dizi etiketlenmiş örneğin öğrenen tarafından kullanılarak daha önce görmediği veriler için öngöründe bulunduğu bir öğrenme şeklidir [40]. Buradaki amaç, veri içinde tahmin edilen özellikler cinsinden sınıf etiketlerinin dağılımını belirtilen gerçekçi bir prototip ortaya koyabilmektir [53]. Öğrenme işi bu öğrenmede makine öğrenmesi tanımlarında da sıklıkla kullanılan veri ya da geçmiş deneyim anlamına gelen bir danışman yardımı ile gerçekleştirilmektedir. Giriş çıkış verilerinin birlikte yer aldığı her bir örnek etiketlenmiş varsayılmaktadır, yani hangi girdi değerine hangi çıktı değerinin karşılık geldiği bilinmektedir. Danışmanlı öğrenme, eğiticili, gözetimli ve denetimli öğrenme biçiminde de adlandırılmaktadır. Gerçek hayattan bir probleme danışmanlı makine öğrenmesi uygulanırken Şekil 3.2'deki adımlar takip edilebilmektedir [54].



Şekil 3. 2. Danışmanlı Öğrenme Süreci [54]

- **Danışmansız Öğrenme:** Eğitim verisinde etiketlenmiş hiçbir örneğinin bulunmadığı öğrenme biçimi olup öğrenen bu eğitim verisi üzerinden öngörde bulunmaktadır [40]. Danışmansız öğrenme literatürde gözetimsiz, eğitici-siz ve denetimsiz öğrenme olarak da adlandırılmaktadır. Başlıca danışmansız öğrenme türlerine boyut indirgeme ve kümeleme örnek olarak verilebilir.[40].

3.2. Sınıflandırma ve Yapay Sinir Ağları

Sınıflandırma insan için kolay iken makine için karmaşık bir görevdir. Makine öğreniminde sınıflandırma yeni bir örneğin veri eğitim kümesine dayanarak hangi kategori kümesine ait olduğunu tespit etme problemidir. Gelen e-mailin önemsiz veya önemsiz olmayan sınıfına ataması veya hasta özelliklerine (cinsiyet, kan basıncı, diğer

belirtiler) göre hasta için bir teşhis ataması sınıflandırma örnekleridir. Sınıflandırma bir örüntü tanıma örneğidir [55]. Bölüm 3.1.2.'de danışmanlı öğrenme giriş ve çıkış verilerinin beraber makineye sunulduğu öğrenme şekli olarak belirtilmişti. Sonlu sayıdaki ayırık sınıfa her bir giriş vektörünü atamayı hedefleyen durumlar sınıflandırma (classification) problemi şeklinde değerlendirilmektedir [56].

Makine öğrenmesinin popüler ve başlıca görevlerinden biri olan sınıflandırma bilinmeyen bir veri parçasının bilinen bir gruba en doğru şekilde yerleştirilmesinde kullanılmaktadır [42]. Sınıflandırmada amaç, daha önce algoritmaya tanıtılmamış örnekleri kavram tanımını elde edildikten sonra en yüksek doğrulukla etiketleyecek sınıflandırıcıyı geliştirmektir [57].

Genelde, örnekler ölçülebilir özellikler kümesi olarak bilinen açıklayıcı değişkenler veya öznitelikler olarak analiz edilir. Bu özellikler kategorik (kan türleri için A, B, AB ve O), sıralı (büyük, orta ve küçük), tam sayısal değer (bir e-maildeki sözcük sayısı), gerçel değer (kan basıncı ölçüsü) olarak sınıflandırılabilir. Sınıflandırıcı ise sınıflandırma algoritmasında girdi verisini uygun sınıfa eşleştirmekte uygulanan matematiksel fonksiyon olarak tanımlanabilir [58].

Makine öğreniminde sınıflandırma için eğitim algoritması seçimi önemli bir adımdır. Bu seçim ve sınıflandırıcının değerlendirilmesi genel olarak tahmin doğruluğuna (doğru tahminin toplam tahmin sayısına bölünen yüzdesi) bakılarak yapılmaktadır. Veri tabanındaki verilerin eğitim ve test kullanımı için farklı yöntemler vardır. İlk yöntem eğitim kümesinin $2/3$ 'ünün eğitim için ve diğer kalan $1/3$ 'lük bölümünü ise performans tahmini veya test için kullanılmaktadır. **Çapraz Doğrulama (Cross-Validation)** olarak bilinen ikinci yöntemde ise eğitim kümesi ayrışık ve eşit boyutta altkümelere bölünmektedir ve her altküme için sınıflandırıcı diğer tüm altkümelerin bileşiminde eğitilir. Her altkümenin hata oranı ortalaması sınıflandırıcının hata oranı tahmini göstermektedir. Hata oranını etkileyen birçok faktör mevcuttur. Veri tabanındaki verilere ait doğrudan ilgili bilgilerin veya özelliklerin (özniteliklerin) kullanılmaması, daha büyük eğitim kümesine ihtiyaç duyulması, küme boyutunun çok büyük olması, seçilen algoritmanın uygunsuzluğu gibi problemler hata oranını etkilemektedir.


Veri sınıflandırılması örüntü tanıma, yapay zeka, istatistik, kavramsal psikoloji, tarımsal uygulamalar, görüntü analizi ve tıp gibi bir çok alanda önemli bir araştırma ve uygulama konusudur. Sınıflandırma için literatürde yaygın olarak kullanılan ve geliştirilen yöntemlerin başında Bayes Sınıflandırma, K En Yakın Komşu (K-Nearest Neighborhood), Karar Ağaçları (Decision Trees), Destek Vektör Makineleri (Support Vector Machines) ve Yapay Sinir Ağları (Artificial Neural Network) sayılabilir. Her problem için farklı bir sınıflandırıcı algoritması daha uygun sonuçlar üretebilmektedir ve bu sebeple en iyi sınıflandırma yöntemi olabilecek tek bir yöntem mevcut değildir [58].

Çağdaş dünyada bilgisayarlar ve bilgisayar sistemleri insan hayatının vazgeçilmez bir parçası haline gelmiştir. Teknolojinin gelişmesiyle birlikte önceden sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirmek üzere geliştirilen bilgisayarların zaman içerisinde büyük miktardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında yorumlar yapabilen nitelikler kazandığı görülmektedir. Diğer bir deyişle artık bilgisayar sistemleri olaylar hakkında bilgiler toplarken, olaylar hakkında değerlendirme yapabilmekte ve olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulmayan problemler dahi bilgisayarlar tarafından sezgisel yöntemler yolu ile çözülebilmektedir. “Yapay zeka”, bilgisayarlara bu yetenekleri katan ve bu yeteneklerinin gelişmesini sağlayan çalışmalar olarak bilinmektedir. 1950’li yıllarda ilk kez ortaya çıkan yapay zeka terimi zamanla yoğun ilgi görmüş ve günümüze kadar gelinen süreçte hayatın zaruri parçası olan sistemlerin doğmasına sebep olmuştur. Yapay Sinir Ağları (YSA), yapay zekayla ilgili çalışmaları da çabuklaştırmıştır. Aslında Yapay zeka ile birlikte YSA özellikle makine öğrenmesini sağlayan ve önemli gelişmelerin habercisi olan, sanayi toplumunun bitip bilgi toplumunun başlamasına neden olan bir unsur olarak karşımıza çıkmıştır [59].

Yapay Sinir Ağları olayların örneklerine bakmakta, örneklerden ilgili olay hakkında bilgiler toplayarak çıkarımlar yapmakta ve hiç görmediği bir olay ile karşılaştığında öğrendiği örneklere ait bilgileri kullanarak o olaylar hakkında karar verebilmektedir. Yapay Sinir Ağları, insan beyninin özelliklerinden olan öğrenme yoluyla yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla

geliştirilen bilgisayar sistemleridir [38]. Yapay Sinir ağları insan beynine benzeyen biyolojik sistemlerden etkilenmiş canlı bir sinir hücresinin basitleştirilerek modellenmiş şeklindedir. Yapay sinir ağları, ağırlık bağlantıları aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işlem yapılarıdır. Genel olarak yapay sinir ağları, model seçimi ve sınıflandırılması, işlev tahmini, en uygun değeri bulma ve veri sınıflandırması gibi işlerde başarılı olan bir yöntemdir [60]. YSA'ya olan ilgi son yıllarda tıp, felsefe, mühendislik, tarım, psikoloji, gibi alanlarda çalışanların YSA'yı kendi uzmanlık alanlarına taşıması ve alanlarıyla ilgili uygulamalar geliştirmeye başlamasıyla ivme kazanmıştır. Teorik ve uygulama alanlarındaki başarılarla da bu ilgi daha da pekiştirilmiştir. İnsana ve insan zekasına özgü olarak değerlendirilen bazı alanların sayısal biçimde ifade edilebileceği ve böylece şaşırtıcı derecede insan zekasına benzer yollarla makinelerin öğrenme işlemini yapabileceği görülmüştür [61].

YSA'nın bilgi işlem birimi yapay sinir ağı hücresidir. Her bir yapay sinir ağı hücresinin 5 temel elemanı bulunmaktadır [38]. Şekil 3.3'te YSA'nın basit bir hücre yapısı gösterilmektedir.



Şekil 3. 3. Yapay Sinir Ağı Hücresinin Yapısı [38]

Dış dünyadan yapay sinir ağı hücresine gelen bilgiler girdiler olarak adlandırılır. Girdiler ağıın öğrenmesi istenen örnekler tarafından belirlenmektedir.


Girdiler yapay sinir ağı hücresine dış dünyadan gelen bilgiler olabildiği gibi başka hücrelerden veya kendi kendisinden de gelen bilgiler olabilmektedir. Bir yapay sinir ağı hücresine gelen bilgilerin yani girdilerin önemini ve hücreye olan etkisini ağırlıklar belirlemektedir. Net girdiyi hesaplayan fonksiyon toplama fonksiyonu olup bunun için değişik fonksiyonlar kullanılabilir. Yaygın olarak ağırlıklı toplam bulunmakta olup her gelen girdi kendi ağırlığı ile çarpılarak toplanır ve ağa gelen net girdi bulunmuş olur. Θ_j bir sabit değerdir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır [38].

$$NET = X_1W_{1j} + X_2W_{2j} + X_3W_{3j} + \dots + X_NW_{Nj} \quad (3.1)$$

Hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı aktivasyon fonksiyonu belirlemektedir [39].

$$y_i = F(NET) + \Theta_j \quad (3.2)$$

Yukarıdaki formüllere göre oluşturulan model gerçek sinir hücresinin en basit haliyle matematiksel olarak ifade edilen formudur. İşlem birimi çıkışı, Şekil 3.4'te gösterilen biyolojik sinir hücrelerinde akson boyunca iletilen sinyale karşılık gelmektedir. Bir sinir hücresinde, nöronun uyarımı arttıkça akson boyunca iletilen sinyalin frekansına artarken, yapay sinir hücresinde çıkış genliği değişmektedir [38].



Şekil 3. 4. Biyolojik Sinir Hücresi

Aktivasyon fonksiyonu yapay sinir hücresine özgü niteliği temsil etmektedir ve toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. En yaygın kullanıma sahip aktivasyon fonksiyonları sigmoid ve tanjant sigmoid fonksiyonlarıdır. Her iki fonksiyonda sınırlı bir aralığa sınırsız aralıkta değişen değerler sıkıştırılmıştır. Sigmoid fonksiyonu 0 ile 1 arasında değerler alırken, tanjant sigmoid fonksiyonu -1 ile 1 arasında değer almaktadır. Her iki fonksiyonda türevleri alınabilen fonksiyonlardır. Sigmoid ve tanjant sigmoid fonksiyonları sırasıyla aşağıda belirtilmiştir [38].

$$F(NE T) = \frac{1}{1 + e^{-NE T}} \quad (3.3)$$

$$f(x) = \frac{1 - e^{-NE T}}{1 + e^{-NE T}} \quad (3.4)$$


Aktivasyon fonksiyonu olarak kullanılan diğer fonksiyonlara ait örnekler Tablo 3.1’de verilmiştir.

Tablo 3. 1. Aktivasyon Fonksiyonu Örnekleri [38]

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon $F(NE T) = NE T$	Girdi verileri olduğu gibi hücrenin çıktısı olarak kabul edilmektedir.
Step Fonksiyonu $F(NE T) = \begin{cases} 1 & \text{Eğer } NE T > \text{eşik değeri} \\ 0 & \text{Eğer } NE T \leq \text{eşik değeri} \end{cases}$	Net girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır
Sinüs Fonksiyonu $F(NE T) = \sin(NE T)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik Değer Fonksiyonu $F(NE T) = \begin{cases} 0 & \text{Eğer } NE T \leq 0 \\ NE T & \text{Eğer } 0 < NE T < 1 \\ 1 & \text{Eğer } NE T \geq 1 \end{cases}$	NE T girdi bilgilerini 0 veya 1’den büyük veya küçük olmasına göre 0 ve 1 arasında değerler alabilir, bunların dışında değerler alamaz.
Hiperbolik tanjant fonksiyonu $F(NE T) = (e^{NE T} + e^{-NE T}) / (e^{NE T} - e^{-NE T})$	Net girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

Yapay Sinir Hücreleri bir araya gelerek yapay sinir ağlarını oluştururlar. Hücrelerin bir araya gelmesi rastgele bir işlem olmayıp genel olarak 3 katman şeklinde ve katmanlar kendi içinde paralel olarak bir araya gelerek ağı oluştururlar. Şekil 3.5'te YSA yapısı ve katmanların birbiri ile ilişkileri gösterilmektedir. YSA katmanları:

- **Girdi katmanı:** Bu katmana ait veri işleme elemanları dışardan gelen bilgileri alarak ara katmanlara transferini gerçekleştirmektedir. Girdi katmanında bazı ağlarda herhangi bir veri işleme olmaksızın gelen bilgiler ara katmanlara iletilmektedir [38].
- **Ara Katmanlar:** Girdi katmanından gelen bilgiler bu katmanda işlenerek çıktı katmanına gönderilmektedir. Girdi katmanından gelen bilgilerin işlenmesi bu katmanda gerçekleşmektedir. Birden fazla ara katman bir yapay sinir ağında olabilmektedir [38].
- **Çıktı Katmanı:** Veri işleme elemanları bu katmanda ara katmandan gelen bilgileri işler ve ağın girdi katmanından sunulan giriş verisi için üretmesi gereken çıktıyı üretirler. Dış dünyaya bu üretilen çıktı gönderilir [38].



Şekil 3. 5. Yapay Sinir Ağı Yapısı ve Katmanların Birbiri ile İlişkileri [38]

Yapay Sinir Ağlarının temel özellikleri aşağıdaki gibidir [62]:

- **Doğrusal Olmama:** YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesiyle meydana gelen Yapay sinir ağı da doğrusal olmamaktadır. Doğrusal olmama özelliği bütün ağa yayılmış durumdadır. YSA bu özelliği ile doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.
- **Öğrenme:** Yapay Sinir Ağının istenilen davranışı gösterebilmesi için amaca uygun olarak hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerekmektedir. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlanmış yada tasarlanmış olarak verilemez. Bundan dolayı YSA, istenen davranışı gösterecek şekilde ilgilendiği problemle ilgili aldığı eğitim örneklerini kullanarak problemi öğrenmektedir.
- **Genelleme:** YSA, problemi öğrendikten sonra eğitim sırasında daha önce karşılaşmadığı test verileri için genelleme yaparak istenilen tepkiyi üretebilir.
- **Uyarlanabilirlik:** YSA ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Bir probleme çözmek maksadıyla eğitilen YSA, problemdeki değişikliklere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitilebilen YSA, uyarlamalı örnek tanıma ve sinyal işleme gibi alanlarda etkin bir biçimde kullanılabilir.
- **Hata Toleransı:** YSA paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağıtılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının veya bazı hücrelerinin etkisiz hale gelmesi ağına bilgi üretme doğruluğunu önemli ölçüde etkilemez. Bu sebeple, hatayı tolere etme yetenekleri son derece yüksektir.

3.3. Yapay Sinir Ağları ile Tarımsal Ürünlerin Sınıflandırılması

Tarımsal ürünlerin sınıflandırılması hem üreticiler için, hem o ürünü pazarlayan sanayici için hem de tüketici için önemli bir unsurdur. Üreticiler ettikleri ürünün cinsini doğru bir yetiştiricilik yapmak amacıyla bilmek, pazarlamacılar da standart oluşturmak amacıyla hedef pazarlar için sattıkları ürünün çeşidinden emin olmak isterler. Bu nedenle tarımsal ürünlerin çeşitlerinin doğru bir şekilde belirlenmesinde güvenilir metotlara ihtiyaç vardır. Geleneksel sınıflandırma metotların

kullanımı yavaş, karmaşık, insan odaklı hatalara açık ve uzman kişilerce tarım ürünlerinin belirlenmesinde elde edilen sonuçlar objektif olmamaktadır. Bu sebeplerden dolayı bilgisayar teknolojilerine dayalı hızlı ve güvenilir yöntemler tercih edilmektedir [63].

Son yıllarda YSA, bulanık mantık, genetik algoritma gibi farklı yapay zeka teknikleri sınıflandırma ve veri analizi için kullanılmakta olup tarımsal uygulamalarda da yaygın olarak görülmektedir [64]. Taneli tahılların iyi bir kurulum ve imgeleme ortamında sınıflandırılmasında tahıl ait alan, çevre uzunluğu, büyük eksen, küçük eksen, esneklik birimi, kompaktlık gibi fiziksel özellikler kullanılmaktadır [65]. Renge dayalı sınıflandırmada, giriş verisi olarak kullanılan görüntü imajı ve dokusundan, nesnenin renk özelliklerine ait bilgiler edinilebilmektedir [66-69]. Yukarıda bahsedilen tahıla ait renk ve biçimsel özellikler kombine bir şekilde kullanılarak sınıflandırma doğruluğu iyileştirilerek tahılların sınıflandırılması yapılmaktadır [66,70].

Visen ve arkadaşları, 5 farklı tahıl çeşidini görüntü işleme ve YSA teknikleri kullanarak sınıflandırmışlardır. Sınıflandırmada performans başarısını yazlık buğday için %99,3, arpa için %98,7, yulaf için %98,4, makarnalık buğday için %96,7, çavdar için ise %96,9 olarak elde etmişlerdir [71].

Baykan ve arkadaşları, görüntü işleme ve YSA tekniklerini kullanarak buğday tanelerini türlerine göre sınıflandırmak amacıyla buğday tanelerine ait 9 fiziksel özellik ve gri seviye ortalamasını bulmuşlardır. Buğday tanesine ait karakteristik özellikler çok katmanlı algılayıcılar ile sınıflandırılmıştır ve beş buğday türü için sınıflandırma başarısı %72,62 olarak bulunmuştur [72].

Üç farklı merkezde yetiştirilmiş üç farklı çeşitte buğdayı Dubey ve arkadaşları sınıflandırmışlardır. YSA kullanılarak yapılan sınıflandırmada 45 adet şekilsel özellik kullanılarak sınıflandırma performansı %88 olarak bulunmuştur [73].

Babalık ve arkadaşları buğday çeşitlerini tespit etmek amacıyla buğday tanelerine ait renk bilgisi ve 9 adet geometrik özellik kullanarak geliştirdikleri YSA modeli ile %90,66 sınıflandırma başarısı elde etmişlerdir [74].

Taner ve arkadaşları makarnalık buğday çeşitlerinin sınıflandırılması amacıyla buğdaylara ait 9 adet fiziksel özellik (geometrik ortalama, çap, bin dane ağırlığı, küresellik, dane hacmi, hacim ağırlığı, özgül ağırlık, yüzey alanı, renk ve porozite) yaptıkları çalışmada kullanmışlardır. Bu çalışmada, M-I, M-II ve M-III olmak üzere 3 farklı çok katmanlı Perseptron, ileri beslemeli (Feed Forward Back Propagation) ağ

yapısı ve Levenberg-Marquardt algoritması kullanılan YSA modeli geliştirilmiştir. M-I modeli için elde edilen sonuçların gerçek veriler ile oldukça uyumlu ve en iyi performans gösteren model olduğu tespit edilmiştir [75].

Paliwal ve arkadaşları 5 farklı tahılın sınıflandırılmasında 4 katmanlı geri yayılım sinir ağları (Back Propagation Neural Network - BPNN) ile parametrik olmayan sınıflandırıcının performansını morfolojik, renk ve doku özellikleri ve bu özelliklerin kombinasyonundan oluşan uygun veri seti belirleyerek kıyaslamıştır. Yapılan çalışmada kullanılan tahıl örnekleri Kanada'nın değişik iklimlerine sahip bölgelerinden seçilmiştir. Sınıflandırma ilk olarak farklı özellik modelleri kullanılarak (sadece morfolojik, sadece renk ve sadece doku özelliği) daha sonra ise tüm bu özellikler kullanılarak yapılmıştır. Her iki sınıflandırıcı için (BPNN ve parametrik olmayan sınıflandırıcı) tüm özelliklerin kullanıldığı sınıflandırma modelinin ayrı ayrı morfolojik, renk ve doku özelliklerinin kullanıldığı modelden daha iyi sonuçlar verdiği görülmüştür [76].

Singh ve arkadaşları 4 farklı pirinç yığınına renk, doku, dalgacık ile renk ve doku özelliklerinin birleşimi olan kombine bir model kullanarak geri yayılım yapay sinir ağ tekniği (BPNN) ile sınıflandırmış ve BPNN sınıflandırma tekniğini diğer sınıflandırma teknikleriyle (destek vektör makineleri, en yakın komşu, Bayes) kıyaslamıştır. Bu çalışmada 4 farklı pirinç yığınına ait 3 farklı veri seti (data set 1, data set 2 (a), data set 2(b)) oluşturulmuştur. Veri setlerine ait görüntüler farklı kalitedeki kameralarla elde edilmiştir. Her bir veri seti için farklı özelliklere ait sınıflandırma doğruluk değerleri BPNN sınıflandırıcıda diğer sınıflandırma tekniklerine göre daha iyi sonuç vermiştir [65].


Bu tezin ilk üç bölümünde Mevcut Tahıl Kontrol Sisteminden, bu sistemin geliştirilmeye açık yönlerinden, mevcut sistemi geliştirmeye yönelik bu tez çalışmasında yapılan çalışmalara ışık tutacak kablosuz ağ teknolojilerinden, makine öğrenmesinden, yapay sinir ağları (YSA) ile sınıflandırmadan ve bu kapsamda literatürde geçen tarımsal ürünlerin sınıflandırılmasına yönelik çalışmalardan bahsedilmiştir. Bundan sonraki bölümde de bu tez çalışmasında mevcut Tahıl Kontrol Sistemini geliştirmeye yönelik yapılan çalışmalar detaylarıyla anlatılacaktır.

4. BÖLÜM

MATERYAL VE METOT


Tahıl Kontrol Sistemi hakkında 1.bölümde bahsedilen problemlerin giderilmesi için bu çalışmada tahıl parametrelerinin (nem, sıcaklık) değişimlerinin kablosuz sensör düğümleri vasıtasıyla ölçülerek, kullanıcı ara yüzüne aktarılması ve izlenmesi amacıyla prototip bir sistem geliştirilmiştir. Tasarlanan yeni sistemde tahılın durumu yeni tasarlanan kullanıcı ara yüzü ile sürekli izlenerek mevcut sisteme göre daha doğru sonuçlar elde edilecektir. Operatör vasıtasıyla alınan ölçümler yerine bilgisayar üzerinden tahıl durumu takip edilerek iş gücü, zaman kaybı ve insan odaklı hataların en aza indirgenmesi amaçlanmaktadır.

Yeni tasarlanacak Tahıl Kontrol Sistemi Şekil 4.1’de gösterildiği gibi Donanım, Yazılım ve Kullanıcı Katmanı olmak üzere üç katmanlı mimariden oluşacaktır.



Şekil 4. 1. Kablosuz Algılayıcı Ağ Temelli Tahıl Kontrol Sistem Mimarisi

Donanım Katmanı RASPERRY Pİ tek kart bilgisayar, sensörler ve kablosuz modüller içeren sensör düğümlerinden oluşmaktadır. Prototip olarak tasarlanan tahıl torbası içerisine metal çubuklar vasıtasıyla sensörler monte edilecek olup bu metal çubuklar torbanın büyüklüğüne ve ihtiyacımıza göre belirli mesafelerde torba içerisine dikey yönde konumlandırılarak sensörlerin içinde tahıl bulunan torbalara yerleştirilmesi sağlanacaktır. Sensörlerden gelen veriler sensör düğümü olarak kullanılan RASPERRY Pİ 3 tek kart bilgisayarına aktarılacaktır. Sistemin kurulum aşamasında Şekil 4.2’de sistemin şematik gösteriminde belirtildiği gibi sensör düğümlerinden birisi yönetici (master), ve diğerleri yönetilen (slave) olarak ayarlanacaktır. Wi-Fi modüllerinin kapsamı alanı dikkate alınarak sensör düğümlerinin kapsama alanına göre prototip torbalar uygun yerlere konumlandırılacak ve gerektiğinde sensör düğümü olarak kullanılan raspberry pi cihazlarından bir tanesi hem master hem de slave düğümü olarak kullanılabilir. Yönetici olan Raspberry Pİ cihazına internet erişimi verilerek ve master ve slave olan tüm sensör düğümlerinin ayarlarındaki doğrulama anahtarının aynı olması sağlanarak sistemin düzgün çalışması sağlanacaktır. Raspberry Pi tek kart bilgisayarının düşük maliyetli, verimli, toplanan verilerin işlenmesi, analizi, bulut sunucuya gönderilmesi ve izlenmesi bakımından pratik bir cihaz olması sebebiyle birçok uygulamada kullanılmaktadır [77].



Şekil 4. 2. Tahıl Kontrol Sistemi Şematik Gösterimi

Yazılım katmanı; veri tabanı, sunucu ve veri işleme görevlerini yerine getirmektedir. Kablosuz sensör düğümleri aracılığıyla alınan sıcaklık ve nem verileri RASPERRY Pİ 3 tek kart bilgisayara, buradan da kablosuz modem kullanılarak oluşturulan yerel ağ vasıtasıyla izleme bilgisayarına aktarılmaktadır. İzleme bilgisayarında yer alan sunucu ara yüzü yardımıyla kullanıcının verileri izleyebilmesi sağlanmakta ve bu veriler aynı zamanda sistemin veri tabanına kaydedilmektedir.

Veri tabanına kaydedilen tahıl durumuna ait sıcaklık ve nem verileri, Yapay Sinir Ağlarıyla MATLAB üzerinden eğitilerek tahılın güvenli, riskli ve tehlikeli (bozulmuş) olarak sınıflandırılması sağlanmıştır. Kullanıcının izleme bilgisayarından gözlemlediği verileri anlık olarak yorumlayabilmesi ve istenmeyen durumların erken tespiti ile tahıla zamanında müdahale etme imkanı sağlanması için MATLAB GUI tasarlanmıştır.

4.1. Kablosuz Sensör Düğümü Tasarımı

Bu bölümde yeni kablosuz Tahıl Kontrol Sistemi için tasarlanan kablosuz sensör düğümü tasarımından ve bu tasarımda kullanılan ekipmanlardan bahsedilmektedir.

Kablosuz sensör düğümü tasarımında aşağıda belirtilen ekipmanlar kullanılmıştır:

- SHT-10 Sıcaklık-Nem Sensörü
- Raspberry Pi 3 Model B Tek Kart Bilgisayarı
- 3G kablosuz Modem
- Mikro SD Hafıza Kartı
- Güç kaynağı (5V DC)

Bu tez çalışmasında tasarlanan prototip tahıl torbası sistemi için 3 adet SHT 10 sıcaklık ve nem sensörü kullanılmıştır. SHT sıcaklık ve nem sensörü Şekil 4.3'te gösterildiği gibi prob şeklinde direkt mikro işlemci veya mikro denetleyiciye bağlanabilir yapıdadır. Prob olarak dizayn edildiğinden yüksek basınca dayanıklıdır ve endüstriyel uygulamalar için uygundur. Söz konusu sensör ayrıca tamamen suya daldırılabilir. Sıcaklık-Nem sensörüne ait teknik özellikler Tablo 4.1'de belirtilmiştir. Söz konusu sensörün aşağıdaki şekilde de belirtildiği gibi; VCC (Güç

Girişi) , GND (Toprak Girişi), DATA (Veri Girişi) ve SCK (Clock Girişi) olmak üzere 4 farklı kablo girişi bulunmaktadır.



Şekil 4. 3. SHT 10 Sıcaklık Nem Sensörü ve Sensöre ait Kablo Bağlantıları


Tablo 4. 1. SHT 10 Sıcaklık Nem Sensörüne ait Teknik Özellikler [78]

Nem Ölçme Aralığı	0-100 % RH
Sıcaklık Ölçme Aralığı	(-40) °C – (+ 123,8) °C
Nem Ölçme Doğruluğu	± 4.5 % RH
Sıcaklık Ölçme Doğruluğu	±0.5 % RH
Tepki Süresi	8 s
Güç Tüketimi	80 µW/s

Kablosuz sensör düğümü tasarımında RaspberryPi 3 Model B cihazı kullanılmıştır. RaspberryPi 3 cihazına maksimum 4 adet sıcaklık nem sensörü bağlanabilmektedir. Raspberyy Pi 3 tek kart bilgisayarı bluetooth ve Wi-Fi özelliklerine sahip olduğundan sensörlerden alınan veriler kablosuz olarak izleme bilgisayarına aktarımı sağlanabilmektedir. Bunun dışında Raspberry Pi 3 cihazı 4 çekirdekli, 64-Bit işlemci 1.2 GHz hızında çalışmaktadır ve 1GB RAM'e sahiptir. Raspberry Pi 3 cihazının Bluetooth özelliği ve USB girişleri sayesinde cihaza kablosuz klavye ve mouse bağlanabilmektedir. Raspberry Pi 3 cihazı Şekil 4.4'te gösterilmekte olup detaylı teknik özellikleri ise Tablo 4.2'de belirtilmiştir.

Tablo 4. 2. Raspberry Pi 3 Model B Teknik Özellikleri [78]

SoC	Broadcom BCM2837
İşlemci	1.2 GHz 64 bit Dört Çekirdekli ARM Cortex-A53
Grafik İşlemci	Broadcom VideoCore IV
Bellek	1GB
USB 2.0 portları	4 Adet
Dahili Depolama	Micro SD Yuvası
Ağ Bağlantısı	10/100Mbit/s Ethernet
GPIO	40 Adet pin çıkışı
Wi-Fi	Dahili Wi-Fi (2.4 GHz 802.11.n)
Bluetooth	4.1 BLE (Bluetooth Low Energy)
Diğer Portlar	HDMI, CSI Kamera Portu, DSI Ekran Portu, Ethernet Portu, 3.5mm analog ses ve video portu




Şekil 4. 4. Raspberry Pi 3 Cihazı

Kablosuz sensör düğümleri yukarıda bahsedilen SHT10 sıcaklık-nem sensörleri ve bu sensörlerin kablo girişlerinin Raspberry Pi 3 cihazının uygun pinlerine bağlanmasıyla oluşturulmuştur. Her bir sensöre, sensöre ait veri sayfasında gösterildiği şekilde Raspberry Pi 3 cihazının kararsız durumda kalmamasını sağlamak ve lojik-1 (high) verisinin cihaza gönderilmesi amacıyla 10 k Ω 'luk pull-up direnç eklenmiştir.


Kablosuz sensör düğümlerinin kurulumunda sensörlerden birisi yönetici (master), diğerleri yönetilen (slave) olarak ayarlanır. Tahıl Torbalarının konumuna ve sayısına göre tek bir Raspberry Pi cihazı üzerinde master ve slave düğümleri kullanılabileceği gibi, her bir torba için birer adet Raspberry Pi cihazı kullanılabilir. Bu tez çalışmasında kullanılan her bir prototip tahıl torbaları için birer adet SHT-10 sıcaklık-nem sensörü kullanılmış, bu sensörler tek bir Raspberry Pi cihazı üzerinde slave ve master olarak programlanmıştır. 1 adet Raspberry Pi cihazı maksimum 4 adet SHT-10 sensörünü desteklediğinden tahıl torbalarının sayısı arttırılmak istenildiği takdirde slave düğümü olarak kullanılacak Raspberry Pi cihazları sisteme eklenerek sensör düğüm sayısı arttırılabilir ve bu sayede kablosuz sensör düğüm ağı genişletilebilir.

Kablosuz sensör düğümleri yazılıma uygun olacak şekilde Raspberry Pi 3 üzerindeki pin çıkışları kullanılarak oluşturulmuştur. Raspberry Pi 3'ün pin çıkışlarına ait detaylı pin diagramı Şekil 4.5'te gösterilmiştir.



Şekil 4. 5. Raspberry Pi 3 Pin Diagramı

Bu çalışmada kullanılan 3 adet SHT-10 sensörünün Raspberry Pi cihazına bağlantı şeması Şekil 4.6’da gösterilmiştir.



Şekil 4. 6. Sensör Bağlantıları

Kablosuz Sensör Düğümünü oluşturulan ekipmanlardan bir diğeri ise şekilde gösterilen kablosuz modemdir. Sensörler vasıtasıyla elde edilen sıcaklık-nem verileri Raspberry Pi 3 cihazından Şekil 4.7’de gösterilen kablosuz modem vasıtasıyla izleme bilgisayarına aktarılmaktadır.




Şekil 4. 7. Kablosuz Modem

Bu tez çalışmasında kullanılan kablosuz modem ile ekstra başka bir cihaza ihtiyaç duyulmadan Raspberry Pi 3 cihazıyla ve izleme bilgisayarı ile yerel ağ üzerinden kablosuz olarak haberleşme sağlanabilmektedir. Kablosuz modem 5200 mAh dahili batarya sayesinde cihaz tam kapasite 16-17 saat boyunca çalışabilmektedir. Cihaz micro USB kablosu ile dizüstü bilgisayar vb. cihazlardan veya kendi adaptörü ile prizden şarj edilerek kesintisiz 3G paylaşımına devam edebilmektedir. Kablosuz modem ile ilgili teknik özellikler Tablo 4.3'te belirtilmiştir.

Tablo 4. 3. Kablosuz Modem Teknik Özellikleri [79]

Boyutlar	100x44,3x28,5 mm
Ekran	OLED
3G Ağ Türü	HSPA+/HSDPA/HSUPA/UMTS
Kullanılan Bant	WCDMA: 900/2100 MHz GSM: 850/900/1800/1900 MHz
İndirme Hızı	21.6 Mbps
Batarya Kapasitesi	5200 mAh
Servis Süresi	16-17 saat
Micro SD Kart Slotu	Var

Sensörler, Raspberry Pi 3 cihazı ve kablosuz modemden oluşan sensör düğümüne ilişkin şematik gösterim Şekil 4.8'de belirtilmiştir.




Şekil 4. 8. Kablosuz Sensör Düğümü Şematik Gösterim

4.2. Kullanıcı Ara yüzü ve Veri Tabanı Tasarımı

Kullanıcı ara yüzü belirlenen zaman aralıklarında tahıla ait nem ve sıcaklık değerlerini ölçen sensörlere ait başlangıç konfigürasyonlarını düzenlemek, sensörleri ölçüp yapması için başlatmak veya istenildiği zaman durdurmak, sensörlerden belirli zaman aralıklarında gelen sıcaklık ve nem verilerini veri tabanına kaydetmek ve kullanıcıya bu verileri tarih sırasına göre listelemek amacıyla tasarlanmıştır. Kullanıcı arayüzü durum sayfası (Status Page) ve Yapılandırma Sayfası (Configuration Page) olmak üzere iki farklı sayfadan oluşmaktadır.

Kullanıcı ara yüzünde konfigürasyon sayfasına girildiğinde daha önce kayıtlı olan sensörlere ilişkin konfigürasyon ayarları görünmektedir. Bu ayarlar veri tabanı yerine yerel diskin ilgili bölümünde tutulmaktadır. Eğer herhangi bir konfigürasyon dosyası bulunamaz ise sayfada bu dosyaya ait sadece bir uyarı görünmektedir. Konfigürasyon sayfasında yerel ağ üzerinde bulunan tüm cihazlar taranabilmektedir. Yerel ağ üzerinde bulunan cihazlar sensör düğümünün yapısına göre kullanılmayan (unused), slave (işçi) ve master (yönetici) olarak sınıflandırılabilir. Bu sayfada seçilen master veya slave cihazları üzerinden kullanılmak istenen PIN seçenekleri ayarlanabilmektedir. Sensörlerden alınacak verilerin isteğe göre ne kadar sürelik bir zaman aralığında gerçekleşeceği yine bu sayfadan belirlenebilmektedir. Sensörlere ait konfigürasyon ayarları yapıldıktan sonra başlama (start) düğmesine basılarak yukarıda bahsedildiği gibi master ve slave olarak seçilen cihazlarla ilgili bağlantılar kurulmaktadır. Herhangi bir sorun çıktığı takdirde başlatma işlemi gerçekleşmez ve ilgili sorun konfigürasyon sayfasındaki Last Error (Son Hata) satırında görülmektedir. Sorunların büyük çoğunluğu bağlantı ve yanlış konfigürasyon (yanlış PIN seçimi gibi) ayarlarından kaynaklanmaktadır. Her başlatma işleminden önce yerel ağ içerisindeki aygıtlar konfigürasyon sayfasındaki “Scan Devices (Aygıtları Tara)” düğmesi ile taratmak bağlantı sorunlarının önüne geçmektedir. Sistem durdurulmak istendiğinde durdurma (Stop) butonu ile durdurulabilmektedir. Kullanıcı ara yüzündeki konfigürasyon sayfasına ait gösterime Şekil 4.9’da yer verilmiştir.

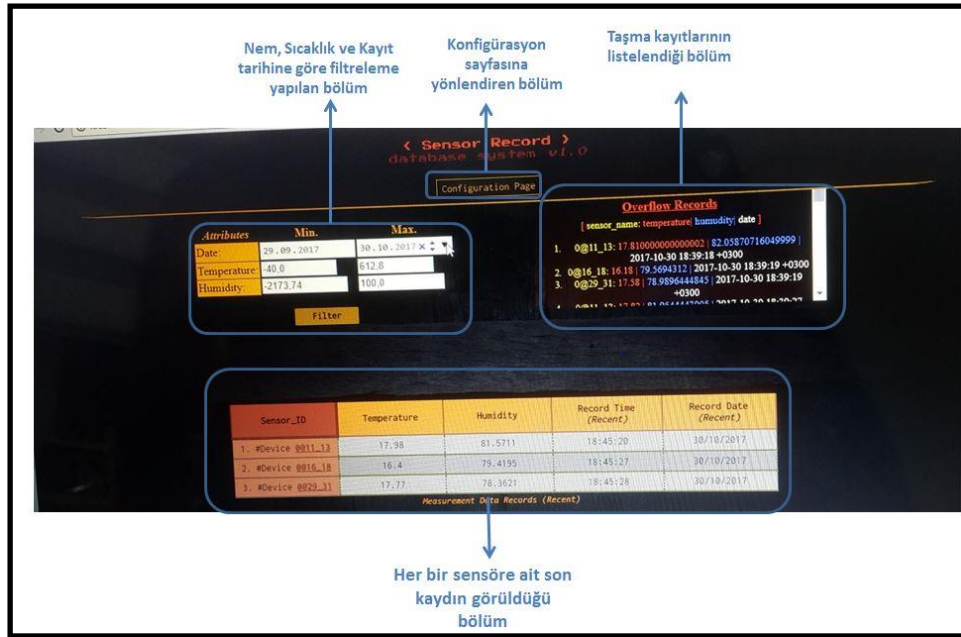


Şekil 4. 9. Kullanıcı Arayüzü Konfigürasyon Sayfası

Kullanıcı ara yüzünde durum sayfasında ise sensörlerden gelen veriler listelenmektedir. Durum sayfasındaki listeleme metotları şu şekildedir:

- Her bir sensöre ait ölçüm aralığına göre kaydedilen son kaydı görüntülemek,
- Tüm sesörlerden elde edilen verileri sıcaklık, nem ve kayıt tarihi değişkenleri kullanarak filtrelemek,
- Her bir sensöre ait tarih sırasına göre elde edilmiş tüm verileri ayrı bir sayfada görebilmek,
- Taşma kayıtlarının (overflow records) sensörlerin pin bağlantılarına ve tarih sıralamasına göre listelenmesi,

Kullanıcı ara yüzündeki durum sayfasına ilişkin gösterim Şekil 4.10'da belirtilmiştir.



Şekil 4. 10. Kullanıcı Arayüzü Durum Sayfası

Durum sayfasında her bir sensöre ait tarih sırasına göre elde edilmiş tüm verilerin ayrı bir sayfada gösterildiği bölüme Şekil 4.11’de yer verilmiştir.

Status Page			
30/10/2017	18:39:59	17.59	78.9399
30/10/2017	18:40:23	17.59	78.9399
30/10/2017	18:40:39	17.60	78.9161
30/10/2017	18:40:47	17.60	78.9442
30/10/2017	18:41:03	17.61	78.8859
30/10/2017	18:41:11	17.62	78.9463
30/10/2017	18:41:27	17.61	78.9204
30/10/2017	18:41:35	17.62	78.9442
30/10/2017	18:41:51	17.63	78.8923
30/10/2017	18:41:59	17.62	78.9527
30/10/2017	18:42:15	17.64	78.8944
30/10/2017	18:42:23	17.62	78.9505
30/10/2017	18:42:39	17.64	78.9225
30/10/2017	18:42:47	17.62	78.9484
30/10/2017	18:43:00	17.65	78.8987
30/10/2017	18:43:15	17.65	78.9548

Şekil 4. 11. Durum Sayfasında Sensörlere Ait Verilerin Listelendiği Bölüm

Kullanıcı arayüz tasarımında nesne tabanlı programlama dili olan Ruby 2.3 kullanılmıştır. Web üzerinden veri tabanına dayanan çalışmaları Ruby ile birlikte gerçekleştirebilmek için bir çerçeve (framework) olan Ruby on Rails 5.0 kullanılmıştır. Veri tabanı olarak Ruby ile uyumlu olan açık kaynak kodlu MySQL kullanılmıştır.

Ruby program ve kütüphanelerinin dağıtımı için standart bir yapı olan Ruby-Gem kullanılmıştır. Veri tabanı tasarımında ayrıca HTML işaretleme dili ile CSS'den faydalanılmıştır. Kullanıcı arayüz uygulamasının sunucu programı olarak Ruby on Rails içerisinde yer alan Puma Server tercih edilmiştir. Bu tez çalışmasında kullanıcı ara yüzü ve veri tabanı tasarımı Bilimsel Araştırma Projeleri Birimi tarafından desteklenen FYL-2017-7141 kodlu proje kapsamında hizmet alımı ile geliştirilmiştir.

4.3. Tasarlanan Tahıl Kontrol Sistemi ile YSA Veri Tabanlarının Oluşturulması

Bu kısımda yeni tasarlanan Tahıl Kontrol Sistemi yardımıyla YSA için gerekli olan eğitim ve test veri tabanının nasıl oluşturulduğu anlatılmaktadır. İlk olarak, sensör düğümleri vasıtasıyla sıcaklık ve nem verilerine ilişkin alınan ölçüm değerlerinin kullanıcı ara yüzüne aktarılması işlemi için 3 adet prototip tahıl torbası (silobag) kullanılmıştır. Prototip tahıl torbaları 2,5 kg tahıl alacak şekilde tasarlanmıştır. Kullanılan 3 adet tahıl torbasında aynı tanecik suyu oranına ve aynı kaliteye sahip buğday (Anadolu Kırmızısı Sert Buğday) kullanılmıştır. Aynı tanecik suyu oranına sahip 3 adet tahıl torbası kullanılmasındaki amaç aynı miktar ve kalitedeki buğdayın sıcaklık ve nem değerlerindeki değişimleri kontrollü bir şekilde gözlemleyerek torbalar arasında karşılaştırma yapabilmek ve alınan verilerinin tutarlılığını değerlendirebilmektir. 3 adet eşit ölçüdeki torbalardaki tahılı yapay sinir ağları vasıtasıyla güvenli, riskli ve tehlikeli (bozulmuş) olarak 3 kategoriye ayırabilmek amacıyla ilk olarak riskli bölge için yaklaşık %17 tanecik suyu oranına sahip tahıldan ölçümler alınmıştır.

%17 tanecik suyu oranına sahip buğdayı elde edebilmek amacıyla TMO bünyesindeki Kaman Ajans Amirliğinden destek alınmıştır. Normal şartlarda %17 tanecik suyu oranına sahip buğdayın sağlıklı depolama koşulları gereği ne TMO bünyesinde ne de özel sektör bünyesindeki depolarda bulunması mümkün olmamaktadır, ancak maksimum %14,5 tanecik suyu oranındaki buğday imkanların çok kısıtlı olduğu durumlarda depolanabilmektedir [80]. %17 tanecik suyu oranına sahip buğday TMO bünyesindeki stoklarda bulunmadığından TMO stoklarında bulunan buğdayın rutubeti Kurumun Ziraat Mühendisi tarafından kalibre edilmiş nemölçer cihazı ile ölçülerek %13,2 tanecik suyu oranı bulunmuş ve bu buğday tavlama yöntemiyle tanecik suyu oranı artırılmak suretiyle kullanılmıştır.

Tavlama, buğdayın sertlik derecesine göre optimum tane suyu düzeyini sağlamak için yapılan taneye su verme veya tanedeki fazla suyu kurutarak taneden uzaklaştırma işlemidir. Buğday tavlama işleminin başarılı olması için sıcaklığın ve dinlenme süresinin tanenin su almasında ve alınan suyun bütün taneye yayılmasında büyük önemi bulunmaktadır [81]. Denklem 4.1’de 100 gr buğday için tavlama formülü gösterilmektedir. N buğdaya verilecek (yüzde olarak) su miktarını (ml), $R1$ buğdayda bulunan su miktarını (ml), $R2$ buğdayda olması istenen su miktarını (ml) ifade etmektedir. Bu formül yardımıyla %13,2 tanecik suyu oranına sahip buğdaydan %17 tanecik suyu oranına sahip buğday elde etmek için 100 g buğdaya ne kadar su ekleneceği hesaplanarak, çalışma kapsamında kullandığımız miktar olan 2,5 kg buğday için oranlanmıştır.

$$N = \frac{100(R2 - R1)}{100 - R2} \quad (4.1)$$

Denklem 4.1’deki tavlama formülüne göre hesaplanan su miktarı 2,5 kg’lık 3 adet prototip tahıl torbasına eklenerek karıştırılmış ve suyun tahıl tanesine bütünüyle yayılabilmesi amacıyla 24 saat boyunca bekletilmiştir. 24 saatin sonunda Şekil 4.12’de gösterilen kalibre edilmiş nem ölçme cihazı ile tahılın nemi (tanecik suyu oranı) TMO’nun yetkili personeline ölçülmüş olup nem değerleri 3 torba için Tablo 4.4’te gösterilmiştir.




Şekil 4. 12. Nem Ölçme Cihazı

Tablo 4. 4. Silobag Torbalarındaki Tahıla Ait Tanecik Suyu Oranları

1 nolu Silobag Torbası	2 nolu Silobag Torbası	3 nolu Silobag Torbası
%17.2	%17.2	%17.3

İstenilen tanecik suyu oranları elde edildikten sonra tahıllar TMO Mucur Ajans Amirliği'nde daha önce hazırlanan ve 1, 2 ve 3 no.lu şeklinde isimlendirilen prototip tahıl torbalarına doldurularak Şekil 4.13'deki gibi torbaların ağzları sızdırmazlık makinesi ile hava almayacak şekilde kapatılmıştır.



Şekil 4. 13. Tahıl Torbalarının Ağzlarının Kapatılmasının Gösterimi

Tahıl torbalarının her birine metal bir çubuk vasıtasıyla sensörler hava almayacak şekilde konumlandırılmıştır. Tahıl torbalarına konumlandırılan sensörlerden tahıla ait sıcaklık ve nem verileri kullanıcı ara yüzü vasıtasıyla sürekli bir şekilde izlenmektedir. Şekil 4.14'de prototip tahıl torbaları gösterilmektedir.



Şekil 4. 14. Prototip Tahıl Torbaları

1, 2 ve 3 no.lu prototip silobaglerdeki sırasıyla %17,2, %17,3 ve %17,3 tanecik suyu oranına sahip tahıllara ait sıcaklık ve nem verileri izlenerek veri tabanına kaydedilmiştir. Söz konusu veriler, her bir sensörden 8 saniye aralıklarla 23 gün boyunca sürekli izlenerek elde edilmiştir. Bu süre zarfında bozulması düşünülen ortalama %17,2 tanecik suyu oranına sahip tahılların, elde edilen verilerden yola çıkılarak bozulma belirtisi göstermediği şeklinde yorum yapılmıştır. Tahıl Torbalarının saydam olmaması sebebiyle verilerden elde edilen sonuçları teyit edebilmek ve tahılın durumunu gözle görebilmek (bozulup bozulmadığını anlayabilmek) için 1 no.lu %17,2 tanecik suyu oranına sahip torba açılmıştır. Açılan torbadaki tahılın durumunun elde edilen verilerle uyumlu olduğu ve tahılda herhangi bir bozulma belirtisi olmadığı görülmüştür. Tablo 4.5'te 1 no.lu torbadaki tahıla ilişkin elde edilen veriler gösterilmektedir.

Tablo 4. 5. 1 No.lu Silobag Torbasından Elde Edilen Veriler

1 nolu Silobag Torbası %17.2 (Riskli)			
Veri Sayısı (Adet)	Verinin Alındığı Tarih	Sıcaklık (°C)	Nem (%)
142.000	30.10.2017	17.81	82.06
	22.11.2017	21.48	84.15

1 no.lu torbadaki tahıl, bozulmanın dışarıdan gözlemlenebilmesi için saydam 5 litrelik pet şişeye aktarılmış ve bu pet şişe “Tehlikeli” olarak etiketlendirmiştir. Buğdayın hızlı bir şekilde kontrollü olarak bozulmasını sağlayabilmek amacıyla 250 ml su pet şişeye eklenmiştir. Tehlikeli olarak etiketlen pet şişedeki tahıla ait veriler izleme sistemi tekrar çalıştırılarak sensör vasıtasıyla alınmaya başlanmıştır. 5 gün boyunca izlenen tahılın nem ve sıcaklık değerlerinde giderek düşme olduğu ve yapılan gözlemlerde de tahılda herhangi bir bozulma ya da değişiklik olmadığı görülmüştür. Dolayısıyla 5 gün sonunda elde edilen bu verilerin “Tehlikeli” tahılın sınıflandırılmasında kullanılacak veriler olmadığına karar verilmiştir. Tablo 4.6'da tehlikeli olarak etiketlenen pet şişedeki tahıla ilişkin veriler gösterilmektedir.

Tablo 4. 6. Tehlikeli Olarak Etiketlenen Pet Şişedeki Tahıla Ait Veriler

5 lt Pet Şişe (Tehlikeli)			
Veri Sayısı (Adet)	Verinin Alındığı Tarih	Sıcaklık (°C)	Nem (%)
16.500	26.11.2017	24.24	98.67
	01.12.2017	22.85	92.03

Tehlikeli olarak etiketlenen pet şişedeki tahılı kontrollü olarak bozabilmek için bu defa pet şişeden alınan bir miktar tahıl tamamen su içerisinde bekletilerek ayrı bir yerde çimlendirilmiştir. Çimlendirilen tahıl pet şişe içerisine kontrollü bozulmayı sağlayabilmek amacıyla aktarılmıştır ve pet şişedeki buğdaya ait sıcaklık nem verileri sensör vasıtasıyla izlenmeye başlanmıştır. Şekil 4.15'te tahılın kontrollü olarak bozulması gösterilmektedir.



Şekil 4. 15. Tahılın Kontrollü Olarak Bozulması

Dış ortamda çimlendirilerek pet şişe içerisine bırakılan tahılın giderek tüm şişeye yayıldığı ve pet şişedeki buğdayın günden güne bozulduğu ilerleyen süreçte gözlemlenmiştir. 46 günlük bu süreçte “Tehlikeli” olarak etiketlenen pet şişedeki tahıldan elde edilen veriler de gözlemlenen verilerle paralellik göstermiştir. Sonuç olarak bu verilerin “Tehlikeli” tahılın sınıflandırılması için kullanılabileceğine karar verilmiştir. Şekil 4.16’da Tehlikeli (Bozulmuş) tahılın son durumu ve Tablo 4.7’de bu tahıla ilişkin veriler yer almaktadır.



Şekil 4. 16. Tehlikeli (Bozulmuş) Tahıl

Tablo 4. 7. Tehlikeli Tahıla Ait Veriler

5 lt Pet Şişe (Tehlikeli)			
Veri Sayısı (Adet)	Verinin Alındığı Tarih	Sıcaklık (°C)	Nem (%)
158.000	19.12.2017	23.48	94.73
	03.02.2018	24.55	98.07

“Riskli” ve “Tehlikeli” sınıfa ait veriler elde edildikten sonra “Güvenli” sınıfına girebilecek verileri temin etmek amacıyla TMO Ankara/Güvercinlik Kazan Ajans Amirliğinden bu defa %13,8 tanecik suyu oranına sahip 2,5 kg’lık diğer 2 sınıfla aynı özellikte tahıl (Anadolu Kırmızısı Sert Buğday) temin edilmiştir. “Güvenli” sınıfına ait verilerin elde edilmesi amacıyla, temin edilen %13,8 tanecik suyu oranına sahip tahıl 5 litrelik pet şişe içerisine konulmuş ve bu pet şişe “Güvenli” olarak etiketlenmiştir. %17,3 tanecik suyu oranına sahip 3 no.lu tahıl torbası açılarak içerisindeki sensör “Güvenli” olarak etiketlenen pet şişe için kullanılmıştır. Sensör pet şişe içerisine sensör girişleri tamamen kapatılarak hava almayacak şekilde yerleştirilmiştir. Sensörün çıkarıldığı “Riskli” olarak etiketlenen 3 no.lu tahıl torbasındaki buğdayda herhangi bir bozulma ya da değişiklik görülmemiştir. Tablo 4.8’de 3 no.lu tahıl torbasına ait veriler gösterilmektedir.

Tablo 4. 8. 3 No.lu Tahıl Torbasına Ait Veriler

3 no.lu Silobag Torbası %17.3 Tanecik Suyu Oranına Sahip (Riskli)			
Veri Sayısı (Adet)	Verinin Alındığı Tarih	Sıcaklık (°C)	Nem (%)
163.000	30.10.2017	17.58	78.98
	24.01.2018	21.27	84.82

“Güvenli” olarak etiketlenen tahıldan da yeterli sayıda veri elde edildikten ve de Riskli, Tehlikeli ve Güvenli sınıfına giren tahıllardan alınan veriler istikrarlı ve güvenilir hale geldiğinden veri alma işlemi sonlandırılmıştır. Böylece tasarlanan Tahıl Kontrol Sistemine ait YSA sınıflandırıcısının Matlab üzerinden eğitilebilmesi ve test edilebilmesi için gerekli olan veri tabanı oluşturulmuştur. Tablo 4.9’da sınıflandırılacak tahıllara ilişkin elde edilen veriler gösterilmektedir.

Tablo 4. 9. Sınıflandırılacak Tahıllara İlişkin Elde Edilen Veriler

Tahıl Durumu	Veri Sayısı
5 lt Pet Şişe (Güvenli)	100.000
2 nolu Silobag Torbası (Riskli)	100.000
5 lt Pet Şişe (Tehlikeli)	100.000
Toplam	300.000

4.4. Yapay Sinir Ağının Eğitiminde Kullanılacak Parametrelerin Seçimi

Bu bölümde tahıla ait nem ve sıcaklık verilerinin Matlab nntool modülü kullanılarak YSA ile eğitilmesinde uygun parametre seçiminin nasıl yapıldığı anlatılmıştır. Matlab nntool modülünde ağın eğitilmesinde kullanılacak sabit ve seçimi yapılan ortak parametreler aşağıda belirtilmiştir:

- Ağ tipi (Network Type) : İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Back Propagation),
- Uyumlu Öğrenme Fonksiyonu (Adaption Learning Function),
- Performans Fonksiyonu (Performans Function),
- Katman Sayısı (Number of Layers),
- Transfer (Aktivasyon) Fonksiyonu (Transfer Function),
- Çevrim Sayısı (Epochs).

YSA eğitiminde kullanılan farklı eğitim algoritmaları ve bu algoritmaların Matlab nntool modülündeki karşılıkları ise aşağıda belirtilmiştir:

- Momentumlu Dereceli Azalma Algoritması (Gradient Descent with Momentum)- Traingdm,
- Levenberg-Marquardt (LM) Algoritması (LM Algorithm) – Trainlm,
- Ölçeklendirilmiş Eşlenik Yaklaşımı Algoritması (Scaled Conjugate Gradient Back Propagation Algorithm)- Trainscg.

Ortak parametrelerden ağ tipi için İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Back Propagation), Uyumlu Öğrenme Fonksiyonu ve “Performans fonksiyonu olarak sırasıyla Learngdm” ve “MSE” (Hata Kareleri Ortalaması-Mean

Square Error) seçilmiştir. Bu parametreler sabit tutularak diğer ortak parametrelerin (aktivasyon fonksiyonu, çevrim sayısı, nöron sayısı, gizli katman sayısı) tespiti “Traingdm” (Momentumlu Dereceli Azalma Algoritması-Gradient Descent with Momentum) eğitim algoritması kullanılarak adım adım yapılmıştır. Ortak parametrelerin tespitinden sonra bu defa farklı eğitim algoritmaları (Trainlm ve Trainscg) kullanılarak o algoritmalara özel en uygun parametre tespiti yapılarak en iyi başarımları veren eğitim ağı bulunmaya çalışılmıştır. Kullanılan eğitim algoritmaları (Traingdm, Trainlm, Trainscg) için yapılan parametre tespiti aşağıda sırasıyla başlıklar halinde belirtilmiştir.

4.4.1. Traingdm Algoritması Kullanılarak En Uygun Ortak Parametrelerin Tespiti

Matlab üzerinden eğitilecek ağın performansı için en uygun ortak parametrelerin belirlenmesinde Traingdm eğitim algoritması kullanılmıştır. Denklem 4.2’de Traingdm’ye ait algoritma belirtilmiştir. Bu algoritma ağırlık ve bias değişkenleri olan x için performansın ($perf$), türevini ($dperf/dx$) hesaplamaktadır [82]. Denklem 4.2’de, “ lr ” ile “ mc ” ifadeleri sırasıyla öğrenme ve momentum katsayısını belirtmektedir. “ $dxprev$ ” ise bir önceki iterasyonda ağırlık ve bias parametrelerine bağlı değişimi ifade etmektedir.

$$dx = mc \times dxprev + lr \times (1 - mc) \times dperf / dx \quad (4.2)$$

Momentumlu Dereceli Azalma Algoritması işleyiş bakımından Standart Geri Yayılım Algoritmasından çok farklı değildir, ancak Standart Geri Yayılım Algoritmasına ek olarak ağırlık katsayılarının güncellenmesinde iki iterasyon öncesine ait ağırlık katsayısı değerleri kullanılmaktadır ve bu değerlere uygun sabit değerler seçilmektedir. Bundan dolayı Momentumlu Dereceli Azalma Algoritmasının başarımları Standart Geri Yayılım Algoritmasından daha iyidir. Bununla birlikte momentum geri yayılımında herhangi bir iterasyon aşamasında hatalı güncelleme yapılırsa, sistem boyunca hatanın etkisi hatalı geri beslemeden dolayı görülmektedir [83].

Traingdm eğitim algoritması kullanılarak ağıımızın performansı için optimum parametreleri belirleyebilmek amacıyla ilk önce öğrenme performansını etkileyen aktivasyon fonksiyonu ve öğrenme katsayısı, daha sonra sırasıyla momentum katsayısı

ile ağıın öğrenmesini durduracak parametre olan çevrim sayısı için farklı değerler denenmiştir.

Aktivasyon fonksiyonun tespiti için tüm parametreler sabit tutularak ağıımızın performansı Tansig, Logsig ve Purelin fonksiyonları için test edilmiştir. MSE ile çıkış değeri için YSA tahmin ve olması gereken değer arasındaki fark değerine bakılarak en iyi aktivasyon fonksiyonunun Purelin olduğuna karar verilmiştir. Tablo 4.10'da aktivasyon fonksiyonunun tespitinin nasıl yapıldığı gösterilmektedir.

Tablo 4. 10. Aktivasyon Fonksiyonunun Tespiti

Aktivasyon Foksiyonu	MSE	Gerçek	Tahmin	Fark%	Fark Ortalama%
TANSİG	0,0057538	1	1,0505	5,05	4,36
		2	2,0572	2,86	
		3	2,8448	5,17	
LOGSIG	0,096516	1	1,1241	12,41	8,03
		2	2,0914	4,57	
		3	2,7865	7,12	
PURELİN	0,0087571	1	1,0110	1,10	2,43
		2	2,0491	2,46	
		3	2,8876	3,75	

Aktivasyon fonksiyonunu tespitinden sonra, Traingdm eğitim algoritmasının özel parametreleri olan öğrenme ve momentum katsayısının seçimi için ilk olarak en uygun öğrenme katsayısı bulunmuştur. Bunun için Tablo 4.10'da en iyi ilk iki sonucu veren Purelin ve Tansig aktivasyon fonksiyonları kullanılarak öğrenme katsayısı her bir aktivasyon fonksiyonu için 0.1-0.9 aralığında değiştirilerek ağıdan elde edilen sonuçlara ve öğrenme katsayısının nasıl tespit edildiğine Tablo 4.11'de yer verilmiştir. Yapılan çalışmalarda öğrenme katsayısının 0.2-0.4 aralığında en optimum sonuçlar verdiği tespit edilmiştir. Bu değer çok büyük seçilmesi, ağıın optimum değerler arasında dolaşmasına, çok küçük seçilmesi ise ağıın öğrenme hızının yavaşlamasına neden olmaktadır [84]. Öğrenme katsayısı için en iyi sonuçlar tüm değerler sabit olmak kaydıyla 0.3 ve 0.4 değerleri için tespit edilmiştir.

Tablo 4. 11. Öğrenme Katsayısı Tespiti

Öğrenme Katsayısının Tespiti						
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)					
Eğitim Algoritması	:Traingdm					
Öğrenme Fonksiyonu	:Learnngdm					
Aktivasyon Fonksiyonu	:Tansig- Purelin					
Nöron Sayısı	:1					
Gizli Hücre Sayısı	:2					
Katman Sayısı	:3					
Gizli Katman Sayısı	: 1					
Momentum Katsayısı	: 0,6					
Çevrim Sayısı	:1000					
Deneme No	Öğrenme Katsayısı	Gerçek Değer	Tahmin Değeri	Fark%	Aktivasyon Fonk.	MSE
1	0,1	1	1,0187	1,87	Tansig	0,00061034
2	0,2	1	1,0207	2,07	Tansig	0,0020437
3	0,3	1	1,0131	1,31	Tansig	0,00061112
4	0,4	1	1,0164	1,64	Tansig	0,00090293
5	0,5	1	1,0133	1,33	Tansig	0,00069924
6	0,6	1	1,0164	1,64	Tansig	0,0003621
7	0,7	1	1,009	0,9	Tansig	0,00056682
8	0,8	1	1,0106	1,06	Tansig	0,00021128
9	0,9	1	1,0099	0,99	Tansig	0,00032302
10	0,1	1	1,0029	0,29	Purelin	0,0019696
11	0,2	1	1,0014	0,14	Purelin	0,00056977
12	0,3	1	1,0001	0,01	Purelin	0,00062255
13	0,4	1	1	0	Purelin	0,00021211
14	0,5	1	1,0004	0,04	Purelin	0,000477
15	0,6	1	1,0001	0,01	Purelin	0,00085336
16	0,7	1	1,0012	0,12	Purelin	0,00018163
17	0,8	1	1,0545	5,45	Purelin	0,17007
18	0,9	1	1,0002	0,02	Purelin	0,00025273

Daha sonra en iyi sonuçları veren 0.3 ve 0.4 öğrenme katsayısı değerleri kullanılarak en uygun momentum katsayısının tespitinde 0.1-0.9 aralığında denemeler yapılmıştır. Öğrenme Katsayısı 0.3 için en iyi sonuç momentum katsayısı 0.6 değerinde, 0.4 için en iyi momentum katsayısı 0.4 ve 0.6 değerleri için elde edilmiştir. Tablo 4.12’te Momentum Katsayısının tespiti gösterilmektedir.

Tablo 4. 12. Momentum Katsayısı Tespit Tablosu

Momentum Katsayısının Tespiti						
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)					
Eğitim Algoritması	:Traingdm					
Öğrenme Fonksiyonu	:Learnngdm					
Aktivasyon Fonksiyonu	:Purelin					
Nöron Sayısı	:1					
Gizli Hücre Sayısı	:2					
Katman Sayısı	:3					
Gizli Katman Sayısı	: 1					
Öğrenme Katsayısı	: 0,3-0,4					
Çevrim Sayısı	:1000					
Deneme No	Momentum Katsayısı	Gerçek Değer	Tahmin Değeri	Fark%	Öğrenme Katsayısı	MSE
19	0,1	3	2,9746	0,846667	0,3	0,00061456
20	0,2	3	2,9702	0,993333	0,3	0,00038428
21	0,3	3	2,972	0,933333	0,3	0,00072758
22	0,4	3	2,9718	0,94	0,3	0,00028061
23	0,5	3	2,9767	0,776667	0,3	0,00056647
24	0,6	3	2,9794	0,686667	0,3	0,00022976
25	0,7	3	2,95	1,666667	0,3	0,0010341
26	0,8	3	2,6138	12,87333	0,3	0,072215
27	0,9	3	2,4478	18,40667	0,3	0,063043
28	0,1	3	2,9756	0,813333	0,4	0,00054354
29	0,2	3	2,9709	0,97	0,4	0,00042293
30	0,3	3	2,9709	0,97	0,4	0,00030938
31	0,4	3	2,9789	0,703333	0,4	0,00021745
32	0,5	3	2,9731	0,896667	0,4	0,00039949
33	0,6	3	2,9864	0,453333	0,4	0,0002917
34	0,7	3	2,9731	0,896667	0,4	0,00032492
35	0,8	3	2,9379	2,07	0,4	0,063746
36	0,9	3	2,8137	6,21	0,4	0,019135

Momentum katsayısının belirlenmesinden sonra çevrim sayısının belirlenmesi için 1000-4000 arasındaki değerler için deneme yapılmıştır. Denemeler 0.4 ve 0.6 değerlerindeki momentum katsayısı için yapılmış olup bu denemelerde öğrenme katsayısı 0.4 olarak alınmıştır. Bu değerler doğrultusunda en iyi sonuç 0.6 değerindeki momentum katsayısı için çevrim sayısı 2500 iken elde edilmiştir. Tablo 4.13'te Çevrim Sayısının Tespiti gösterilmektedir.

Tablo 4. 13. Çevrim Sayısının Tespiti

Çevrim Sayısının Tespiti						
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)					
Eğitim Algoritması	: Traingdm					
Öğrenme Fonksiyonu	: Learngdm					
Aktivasyon Fonksiyonu	: Purelin					
Nöron Sayısı	: 1					
Gizli Hücre Sayısı	: 2					
Katman Sayısı	: 3					
Gizli Katman Sayısı	: 1					
Öğrenme Katsayısı	: 0,4					
Momentum Katsayısı	: 0.4-0.6					
Deneme No	Çevrim Sayısı	Gerçek Değer	Tahmin Değeri	Fark%	Momentum Katsayısı	MSE
37	1000	3	2,9696	1,013333	0,4	0,00046104
38	1250	3	2,9792	0,693333	0,4	0,00040065
39	1500	3	2,9808	0,64	0,4	0,00037926
40	1750	3	2,9787	0,71	0,4	0,00021184
41	2000	3	2,9793	0,69	0,4	0,00031919
42	2500	3	2,9823	0,59	0,4	0,00011256
43	3000	3	2,9825	0,583333	0,4	0,00023362
44	3500	3	2,9849	0,503333	0,4	0,00010769
45	4000	3	2,9199	2,67	0,4	0,0033561
46	1000	3	2,9598	1,34	0,6	0,0018818
47	1250	3	2,9729	0,903333	0,6	0,00035531
48	1500	3	2,9843	0,523333	0,6	0,00023938
49	1750	3	2,9767	0,776667	0,6	0,00043548
50	2000	3	2,9799	0,67	0,6	0,00058091
51	2500	3	2,9884	0,386667	0,6	0,00018228
52	3000	3	2,9843	0,523333	0,6	0,00016625
53	3500	3	2,986	0,466667	0,6	8,89E-05
54	4000	3	2,9851	0,496667	0,6	0,00015479

Çevrim sayısının belirlenmesinden sonra nöron sayısı için 1-20 arasında denemeler yapılmıştır. Yapılan denemelerde en iyi sonuç 12 değerinde elde edilmiştir. Nöron sayısı ağı ilişkin yapısal özelliklerden bir tanesi olup bir katmandaki nöron sayısının olabildiğince az olması tercih edilmektedir. Bunun nedeni; nöron sayısının çok fazla olması ağı verileri ezberlemesine, çok az olması da ağı genelleme yeteneğini arttırmasına yol açmasıdır [84]. Tablo 4.14’da nöron sayısının tespiti yer almaktadır.

Tablo 4. 14. Nöron Sayısının Tespiti

Nöron Sayısının Tespiti						
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)					
Eğitim Algoritması	:Traingdm					
Öğrenme Fonksiyonu	:Learnsgdm					
Aktivasyon Fonksiyonu	:Purelin					
Nöron Sayısı	:1					
Gizli Hücre Sayısı	:2					
Katman Sayısı	:3					
Gizli Katman Sayısı	: 1					
Öğrenme Katsayısı	: 0,4					
Momentum Katsayısı	:0.6					
Çevrim Sayısı	:2500					
Deneme No	Nöron Sayısı	Gerçek Değer	Tahmin Değeri	Fark%	Çevrim Sayısı	MSE
55	1	3	2,9764	0,786667	2500	0,00035133
56	2	3	2,9867	0,443333	2500	7,60E-05
57	3	3	2,9547	1,51	2500	0,0005738
58	4	3	2,9814	0,62	2500	0,00011694
59	5	3	2,9737	0,876667	2500	0,00037155
60	6	3	2,9866	0,446667	2500	7,47E-05
61	7	3	2,9526	1,58	2500	0,0022047
62	8	3	2,9518	1,606667	2500	0,0019144
63	9	3	2,947	1,766667	2500	0,0032824
64	10	3	2,9945	0,183333	2500	0,00022756
65	11	3	2,9888	0,373333	2500	0,00020832
66	12	3	3	0	2500	0,062904
67	13	3	2,9995	0,016667	2500	0,00072093
68	14	3	2,9798	0,673333	2500	0,0002095
69	15	3	2,9899	0,336667	2500	0,00010346
70	16	3	2,9993	0,023333	2500	7,02E-06
71	17	3	2,9973	0,09	2500	3,84E-06
72	18	3	2,9795	0,683333	2500	0,000758
73	19	3	2,9808	0,64	2500	0,00021428
74	20	3	2,9837	0,543333	2500	3,02E-04

Nöron sayısının belirlenmesinden sonra gizli katman sayısının belirlenmesi gerekmektedir. Gizli katman sayısının belirlenmesi için piramit kuralı uygulanmıştır. Bu kurala göre, bir ağ için kullanılacak olan gizli katman sayısı, girdi hücre sayısı ve çıktı hücre sayısının çarpımının karekökünden küçük olamaz [84]. Ağımızda girdi hücre sayısı 2, çıktı hücre sayısı 1 olduğundan gizli katman sayısı 2, 3 veya 4 değerlerinden biri olmalıdır. 2, 3 ve 4 değerleri için yapılan denemeler sonucunda en iyi sonuç 3 değerinde elde edilmiştir. Tablo 4.15'te gizli katman sayısının tespiti belirtilmiştir.

Tablo 4. 15. Gizli Katman Sayısının Tespiti

Gizli Katman Sayısının Tespiti						
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)					
Eğitim Fonksiyonu	:Traingdm					
Öğrenme Fonksiyonu	:Learngdm					
Aktivasyon Fonksiyonu	:Purelin					
Nöron Sayısı	:12					
Katman Sayısı	:3					
Öğrenme Katsayısı	: 0,4					
Momentum Katsayısı	:0.6					
Çevrim Sayısı	:2500					
Deneme No	Gizli Katman Sayısı	Gerçek Değer	Tahmin Değeri	Fark%	Nöron sayısı	MSE
75	2	3	2,998	0,066667	12	0,00010547
76	3	3	3	0	12	2,19E-01
77	4	3	2,9998	0,006667	12	6,31E-04

Yukarıda adım adım açıklanan tüm parametre seçimlerinin sonucunda Tablo 4.16’da ağın eğitiminde kullanılan optimum değerler belirtilmiştir.

Tablo 4. 16. Ağa Ait Optimum Ortak Parametre Değerleri

Aktivasyon Fonksiyonu	Purelin
Çevrim Sayısı	2500
Nöron Sayısı	12
Gizli Katman Sayısı	3

4.4.2. Ortak Parametreler Kullanılarak Trainlm Özel Parametrelerinin Tespiti

Bu bölümde tespit edilen ortak parametreler kullanılarak “Trainlm” (Levenberg-Marquardt (LM)) eğitim algoritmasına ait en uygun özel parametreler belirlenmiştir. İlk olarak Levenberg-Marquardt (LM) algoritması kısaca açıklanarak bu algoritmaya özel “mu” ve “mu_dec” parametrelerinin nasıl seçildiği anlatılmaktadır.

Yapay sinir ağlarının eğitiminde Levenberg-Marquardt (LM) algoritması sağladığı hız ve kararlılık nedeniyle tercih edilmektedir. Ancak düşük eğitim verimi ve kötü yakınsama hızı gibi dezavantajları bulunmaktadır. Genellikle geri yayılım algoritması ile tercih edilen Trainlm’de dinamik öğrenme oranı geri yayılım algoritmasının hızını arttırmaktadır. LM algoritması Newton algoritma hızını ve dik iniş (steepest descent) metodunun kararlılığını birleştirerek günümüz ağ eğitiminde etkili olarak kullanılmaktadır [85]. Denklem 4.3’te LM algoritması gösterilmiştir.

$$\Delta w = \left(J^T J + \mu I \right)^{-1} J^T e \quad (4.3)$$

Denklem 4.3’te w ağırlık vektörü, I birim matris, μ (mu değeri) kombinasyon katsayısıdır. J ($P \times M$) $\times N$ boyutunda Jacobian matrisini, e ($P \times M$) $\times 1$ boyutunda hata vektörünü göstermektedir. P eğitim örnek sayısını, M çıkış sayısını ve N ağırlık sayısını göstermektedir. μ ayarlanabilir bir parametredir. Bu parametre çok büyükse yöntem dik iniş metodu gibi, çok küçükse Newton metodu gibi davranmaktadır [85]. Denklem 4.3’te μ değeri için uyarlamalı bir yapı gösterilmektedir. Denklem 4.4’te k sabit bir sayı olup E uygunluk değerini göstermektedir.

$$\mu(n) \begin{cases} \mu(n-1)k & E(n) > E(n-1) \\ \mu(n-1)/k & E(n) \leq E(n-1) \end{cases} \quad (4.4)$$

E uygunluk değeri Denklem 4.5’te gösterilmiştir.

$$E_n = \frac{1}{2} \sum_j j e_j^2 \quad (4.5)$$

Denklem 4.5’te ifade edilen e_j hata değerini belirtmektedir. “ e_j ” Denklem 4.6’da ifade edilmiştir. j örnek indeksini, yd_j istenen çıkış değerini göstermektedir.

$$e_j = yd_j - y_j \quad (4.6)$$

Trainlm algoritmasına ait özel optimum parametre seçiminde diğer tüm parametreler sabit tutulduğunda (mu_dec, mu_max, mu_inc) μ (mu) değeri için en iyi sonucu veren değerin 0,01 ve 0,00002 olduğu tespit edilmiştir. Tablo 4.17’de en uygun mu değerinin tespitinin nasıl yapıldığı belirtilmiştir.

Tablo 4. 17. Trainlm Algoritmasında μ (mu) Değerinin Tespiti

Levenberg-Marquardt algoritmasına göre mu değerinin tespiti							
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Algoritması	:Trainlm (Levenberg-Marquardt)						
Öğrenme Fonksiyonu	:Learnqdm						
Aktivasyon Fonksiyonu	:Purelin						
Nöron Sayısı	:12						
Katman Sayısı	:3						
Gizli Katman Sayısı	: 1						
Çevrim Sayısı	:2500						
mu_dec	:0,1						
mu_inc	:10						
mu_max	:10000000000						
Deneme No	mu değeri	Gerçek Değer	Tahmin Değeri	Fark%	Fark% Ortalama	Epoch Değeri	MSE
1	0,001	1	1	0,0000	1,2867	12	0,0014942
		2	2,0702	3,5100			
		3	2,9895	0,3500			
2	0,002	1	1	0,0000	1,2906	18	0,0014265
		2	2,0705	3,5250			
		3	2,9896	0,3467			
3	0,003	1	1	0,0000	1,2939	11	0,0013707
		2	2,0709	3,5450			
		3	2,9899	0,3367			
4	0,01	1	1	0,0000	1,2833	9	0,0014665
		2	2,0702	3,5100			
		3	2,9898	0,3400			
5	0,02	1	1	0,0000	1,2856	17	0,0014619
		2	2,0702	3,5100			
		3	2,9896	0,3467			
6	0,03	1	1	0,0000	1,2844	5	0,0015205
		2	2,0702	3,5100			
		3	2,9897	0,3433			
7	0,1	1	1	0,0000	1,2917	12	0,0014706
		2	2,0705	3,5250			
		3	2,9895	0,3500			
8	0,0001	1	1	0,0000	1,2844	11	0,0014742
		2	2,07	3,5000			
		3	2,9894	0,3533			
9	0,0002	1	1	0,0000	1,2917	12	0,0014457
		2	2,0705	3,5250			
		3	2,9895	0,3500			
10	0,0003	1	1	0,0000	1,2872	12	0,0014706
		2	2,0703	3,5150			
		3	2,9896	0,3467			
11	0,00001	1	1	0,0000	1,2850	12	0,00148
		2	2,0703	3,5150			
		3	2,9898	0,3400			
12	0,00002	1	1	0,0000	1,2833	11	0,0014467
		2	2,07	3,5000			
		3	2,9895	0,3500			
13	0,00003	1	1	0,0000	1,2894	20	0,0014642
		2	2,0705	3,5250			
		3	2,9897	0,3433			

Trainlm algoritması için optimum “ μ ” (mu) değeri tespit edildikten sonra diğer bir özel parametre olan “mu_dec” değeri için en uygun değer bulunmuştur. Bunun için optimum değer olarak tespit edilen 0,01 ve 0,00002 değerlerinden MSE değeri daha düşük olan 0,01 değeri tercih edilmiş ve bu değerle beraber diğer tüm parametreler (mu, mu_inc, mu_max) sabit tutularak en uygun mu_dec değeri 0,0005 olarak bulunmuştur. Tablo 4.18’de mu_dec değerinin tespiti gösterilmektedir.

Tablo 4. 18. Trainlm Algoritmasında mu_dec Değerinin Tespiti

Levenberg-Marquardt algoritmasına göre mu_dec değerinin tespiti							
Ağ Tipi	: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Algoritması	:Trainlm (Levenberg-Marquardt)						
Öğrenme Fonksiyonu	:Learnngdm						
Aktivasyon Fonksiyonu	:Purelin						
Nöron Sayısı	:12						
Katman Sayısı	:3						
Gizli Katman Sayısı	: 1						
Çevrim Sayısı	:2500						
mu	:0,00002						
mu_inc	:10						
mu_max	:10000000000						
Deneme No	mu_dec	Gerçek Değer	Tahmin Değeri	Fark%	Fark% Ortalama	Epoch Değeri	MSE
1	0,1	1	1	0,0000	0,8061	12	0,0014935
		2	2,0413	2,0650			
		3	2,9894	0,3533			
2	0,005	1	1	0,0000	0,8039	11	0,0014326
		2	2,0415	2,0750			
		3	2,9899	0,3367			
3	0,01	1	1	0,0000	0,8206	4	0,001468
		2	2,0421	2,1050			
		3	2,9893	0,3567			
4	0,005	1	1	0,0000	0,8244	4	0,0014736
		2	2,0426	2,1300			
		3	2,9897	0,3433			
5	0,001	1	1	0,0000	0,8056	15	0,0015073
		2	2,0414	2,0700			
		3	2,9896	0,3467			
6	0,0005	1	1	0,0000	0,8028	8	0,0015185
		2	2,0411	2,0550			
		3	2,9894	0,3533			
7	0,0001	1	1	0,0000	0,8044	13	0,0014463
		2	2,0414	2,0700			
		3	2,9897	0,3433			

4.4.3. Ortak Parametreler Kullanılarak Trainscg Özel Parametrelerinin Tespiti

Trainlm algoritmasının özel parametreleri için en uygun değerler tespit edildikten sonra Trainscg (Scaled Conjugate Gradient – Ölçeklendirilmiş Eşlenik Yaklaşımı) algoritması için de en uygun parametre tespiti yapılmıştır. Bu kısımda, öncelikle Trainscg algoritması ile ilgili teorik bilgilere yer verilmiş daha sonra bu algoritmaya ait özel parametreler olan sigma (σ) ve lambda (λ) için optimum değerlerin nasıl belirlendiği gösterilmiştir.

Trainscg algoritması çoğu problemde süper doğrusal (süper linear) yaklaşım gösteren eşlenik yaklaşım(conjugate gradient) metotlarından biridir. Adım büyüklüğü ölçeklendirme mekanizması (step size scaling mechanism) kullandığından her bir öğrenme tekrarı başına yol keşfinden (line-search) kurtulmaktadır. Bu sayede zaman kaybı önlendiğinden diğer ikinci derece algoritmalarına göre daha hızlı olma özelliği kazanmıştır. Moller tarafından literatüre kazandırılan bu algoritma Denklem 4.7' de gösterilmektedir [86,87].

$$S_k = \frac{E'(w_k + \sigma_k \rho_k) - E'(w_k)}{\sigma_k} + \lambda_k \rho_k \quad (4.7)$$

Denklem 4.7'de belirtilen S Hessian matris yaklaşımı, E toplam fonksiyon hatası, E' , E 'nin gradyanı, λ_k ve σ_k parametreleri, Hessian matrise yaklaşım için kullanılan ölçekleme faktörleridir. Bu parametreler algoritmanın başında $0 < \lambda_k < 10^{-6}$ ve $0 < \sigma_k < 10^{-4}$ aralığında olacak şekilde belirlenir. ρ_k değerinin hesaplanmasında kullanılan ve eşlenik yaklaşım metotları arasında farklılığa neden olan β_k faktörünün hesaplanması Denklem 4.8 ve 4.9'da belirtilmiştir [87].

$$\beta_k = \frac{|g_{k+1}|^2 - g_{k+1}^t g_k}{g_k g_k^T} \quad (4.8)$$

$$\rho_{k+1} = -g_{k+1} + \rho_k \beta_k \quad (4.9)$$

Trainscg algoritmasının özel parametreleri olan sigma (σ) ve lambda (λ) için en uygun değerlerin tespitinde ilk olarak en uygun sigma değerinin tespiti yapılmıştır. Bunun için diğer tüm parametreler sabit tutulmuş ve sigma değeri 5e-1 olarak tespit edilmiştir. Daha sonra sigma değeri 5e-1 alınarak diğer parametreler sabit olmak kaydıyla en uygun lambda (λ) değeri 5e-1 olarak bulunmuştur. Tablo 4.19'da sigma ve lambda değerlerinin tespiti gösterilmektedir.

Tablo 4. 19. Trainscg Algoritması için Sigma ve Lambda Değerlerinin Tespiti

Scaled Conjugate Gradient (SCG) algoritmasına göre sigma ve lambda değerlerinin tespiti								
Ağ Tipi		: İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Algoritması		:Trainscg (Scaled Conjugate Gradient BackPropagation)						
Öğrenme Fonksiyonu		:Learnsgdm						
Aktivasyon Fonksiyonu		:Purelin						
Nöron Sayısı		:12						
Katman Sayısı		:3						
Gizli Katman Sayısı		: 1						
Çevrim Sayısı		:2500						
Den. No	sigma	lambda	Gerçek Değer	Tahmin Değeri	Fark%	Fark% Ortalama	Epoch Değeri	MSE
1	5e-05	5e-07	1	1	0,0000	1,2561	3	0,0014121
			2	1,9315	3,4250			
			3	2,9897	0,3433			
2	5e-03	5e-07	1	1	0,0000	1,2533	21	0,0013832
			2	1,9318	3,4100			
			3	2,9895	0,3500			
3	5e-01	5e-07	1	1	0,0000	1,2528	72	0,00142
			2	1,9317	3,4150			
			3	2,9897	0,3433			
4	5e-07	5e-07	1	1	0,0000	1,2561	24	0,0014665
			2	1,9317	3,4150			
			3	2,9894	0,3533			
5	5e-09	5e-07	1	1	0,0000	1,2528	27	0,0014351
			2	1,9317	3,4150			
			3	2,9897	0,3433			
6	5e-01	5e-09	1	1	0,0000	1,2500	35	0,0014735
			2	1,9318	3,4100			
			3	2,9898	0,3400			
7	5e-01	5e-11	1	1	0,0000	1,2633	32	0,0015074
			2	1,931	3,4500			
			3	2,9898	0,3400			
8	5e-01	5e-05	1	1	0,0000	1,2622	58	0,0014464
			2	1,931	3,4500			
			3	2,9899	0,3367			
9	5e-01	5e-03	1	1	0,0000	1,2600	73	0,0015191
			2	1,9312	3,4400			
			3	2,9898	0,3400			
10	5e-01	5e-01	1	1	0,0000	1,2500	82	0,0014605
			2	1,932	3,4000			
			3	2,9895	0,3500			

Bölüm 4.4.1, 4.4.2 ve 4.4.3'te tespit edilen ve eğitim kısmında kullanılan optimum ortak parametre değerleri ile Traingdm, Trainlm ve Trainscg eğitim algoritmaları için tespit edilen optimum özel parametre değerlerini gösterir özet tablo Tablo 4.20'de belirtilmiştir.

Tablo 4. 20. Traingdm, Trainlm ve Trainscg için Elde Edilen Optimum Değerler

3 FARKLI EĞİTİM FONKSİYONU (Traingdm, Trainlm, Trainscg) İÇİN YAPILAN DENEMELER SONUCUNDA ELDE EDİLEN OPTİMUM DEĞERLER			
Parametreler	Eğitim Fonksiyonu		
	Traingdm	Trainlm	Trainscg
Ağ tipi	Feed Forward Back Propagation	Feed Forward Back Propagation	Feed Forward Back Propagation
Öğrenme Fonksiyonu	Learngdm	Learngdm	Learngdm
Aktivasyon Fonksiyonu	Purelin	Purelin	Purelin
Nöron Sayısı	12	12	12
Gizli Katman Sayısı	3	3	3
Çevrim Sayısı	2500	2500	2500
Momentum Katsayısı	0,6		
Öğrenme Katsayısı	0,4		
Mu değeri		0,00002	
Mu_dec değeri		0,0005	
Mu_inc değeri		10	
Mu_max değeri		10000000000	
Sigma Değeri			5e-01
Lambda Değeri			5e-01

4.5. YSA ile Verilerin Eğitimi ve Test Edilmesi

Ağın eğitiminde kullanılacak parametrelerin tespiti yapıldıktan 3 farklı eğitim algoritması (Traingdm, Trainlm, Trainscg) için Matlab nntool modülü kullanılarak YSA ile eğitim aşamasına geçilmiştir. Bunun için Tahıl Kontrol Sistemine ait veri tabanından kullanıcı arayüzüne aktarılan sıcaklık ve bağıl nem değerleri giriş verisi olarak kullanılmıştır. Çıkış verisi olarak ise depolanan tahılın sıcaklık ve bağıl nem değerlerine göre olması gereken depolanma durumları (güvenilir, riskli, tehlikeli) kullanılmıştır. YSA çıktı verileri aşağıdaki tabloda belirtilmiştir. Çıktı (output) verileri güvenli depolama için 1, riskli depolama için 2, tehlikeli depolama için 3 olarak numaralandırılmış olup Tablo 4.21’de gösterilmektedir.

Tablo 4. 21. YSA Çıktı Verileri

Güvenli Depolama	1
Riskli Depolama	2
Tehlikeli Depolama	3


“Güvenli”, “Riskli” ve “Tehlikeli” olarak etiketlenen 3 farklı tahıl sınıfına ait 100.000’er veri olma üzere toplamda 300.000 verinin %80’i (240.000) eğitim verisi olarak %20’si (60.000) ise test verisi olarak kullanılmıştır.

Bahse konu kullanılacak eğitim ve test verilerinin excel formatında düzenlenmiş olup kısa bir gösterimi Tablo 4.22’de belirtilmiştir.

Tablo 4. 22. YSA Eğitim ve Test Verilerinin Kısa Gösterimi

Giriş Verileri		Çıkış Verileri
Sıcaklık (°C)	Nem %	Tahıl Durumu
22,37	47,53	1
22,23	47,53	1
22,02	85,06	2
21,88	84,97	2
23,51	94,17	3
22,17	93,97	3
20,76	45,95	1
22,22	48,04	1
23,47	95,66	3
23,29	96,63	3
22,00	85,08	2
21,87	84,97	2
21,63	46,08	1
23,42	93,07	3

Tablo 4.22’de kısa gösterimi belirtilen Excel formatında kayıtlı bu verilerden ilk olarak ağın eğitimi için kullanılan 240.000 veri ($[240.000 \times 3]$) Matlab’a aktarılarak Matlab YSA nnttool ara yüzü için giriş ($[2 \times 240.000]$) ve çıkış ($[1 \times 240.000]$) matrisi oluşturulmuştur. Giriş ve çıkış matrisleri kullanılarak oluşturulan eğitim ağında optimum ağ performansı için “Train” kısmında ağa ilişkin en uygun parametreler seçilmiştir. Ağın eğitimi tamamlandığında ağın performans ve regresyon grafikleri elde edilmiştir. Bu grafiklerden ağın hata kareleri ortalamasına (Mean Error Square-MSE) bakılarak gösterdiği performansı ve elde edilen çıktı değerlerinin hedef çıktıya göre regresyon eğrileri görülebilmektedir. Eğitim kısmındaki işlemler sonlandırıldığında ağın test edilmesi için bu defa eğitim verilerini içermeyen test veri tabanına ait 60.000 adet veri Matlab’a aktarılmış ve nntool ara yüzü için giriş matrisi ($[2 \times 60.000]$) oluşturulmuştur. Bu giriş verileri oluşturulan eğitim ağı üzerinden nntool modülünün “Simulate” kısmı kullanılarak test edilmiş ve çıkış matrisi ($[60.000 \times 1]$) elde edilmiştir. Elde edilen çıkış matrisi olması gereken çıkış matrisiyle karşılaştırılarak üç farklı eğitim algoritması için (Traingdm, Trainlm, Trainsrc) başarı oranları tespit edilmiştir. Bu başarı oranlarına tezin sonuç kısmında diğer grafiklerle (Ağ Eğitim Performans ve Ağ Başarı Oranı grafikleri) birlikte yer verilmiştir. Şekil 4.17’de bu tez kapsamında tasarlanan Tahıl Kontrol Sistemi ile eğitim ve test veri tabanlarının elde edilmesinden sonra bu veriler yardımıyla YSA tahıl durum sınıflandırıcısı oluşturulmasında eğitim ve test aşamalarının şematik gösterimi ve akış diyagramı yer almaktadır.



Şekil 4. 17. YSA Tahlil Durum Sınıflandırıcı Oluşturulması Aşamaları

4.6. Matlab Grafiksel Kullanıcı Ara Yüzü (GUI)Tasarımı

Tahıl kontrol sisteminden sensörler vasıtasıyla anlık olarak okunan verilerin YSA eğitim ağı kullanılarak Matlab üzerinden “Güvenli” “Riskli” ve “Tehlikeli” şeklinde sınıflandırılması ve kullanıcı tarafından sınıflandırılmış bu verilerin kolaylıkla izlenebilmesi amacıyla Matlab Grafiksel Kullanıcı Ara Yüzü (GUI) tasarlanmıştır.

GUI içeriğinde yer alan nesnelerin kullanılması ile kullanıcıyla etkileşimini ve bir işin veya bir programın işletilmesini sağlayan grafiksel bir program ara yüzüdür. GUI açılımı “Graphical User Interface” olarak şeklindedir.


GUI içeriği; menüler, araç çubukları, radio butonları, liste kutuları, kaydırıcılar, push butonlar, vb. nesnelerden oluşmaktadır. Ayrıca Matlab GUI ile Matlab’ın sunduğu hesaplama olanakları kullanılarak veri alımı ve grafik çizimi gibi pek çok işlem gerçekleştirebilmektedir.

Bu çalışmada tasarlanan GUI ile aşağıda belirtilen işlemler gerçekleştirilebilmektedir:

- Tahıl Kontrol Sisteminden sensörler vasıtasıyla anlık olarak okunan tahıla ait sıcaklık ve nem verilerinin kullanıcı tarafından girilebilmesi,
- Girilen sıcaklık ve nem değerlerine göre bu çalışma kapsamında eğitilen YSA üzerinden test sonucunun kullanıcıya gösterilmesi,
- Son olarak da test sonucunun tahılın 1-3 aralığında sınıflandırılma durumuna göre (1=Güvenli, 2=Riskli, 3=Tehlikeli) yorumlanabilmesi sağlanmaktadır.

Matlab GUI tasarımı yapılırken “GUIDE” denilen grafiksel geliştirme ortamı kullanılır. GUIDE içerisinde çeşitli araçlar barındırmakta olup GUI tasarımında kullanıcıya kolaylıklar sağlamaktadır. GUIDE ile tıkla ve sürükle-bırak tekniği kullanılarak GUI ara yüzüne nesneler (örneğin butonlar, text kutuları, liste kutuları, grafikler, vs.) kolaylıkla eklenebilir. Ayrıca, eklenen nesnelerin hizalanması, istenilen değişikliklerin görsel ayarlar üzerinde yapılması da bu ortamın tasarımcılara sunduğu imkânlardan bazılarıdır.


Matlab GUIDE aracı vasıtasıyla tasarlanan GUI şablonu Şekil 4.18’de gösterilmiştir.




Şekil 4. 18. Tasarlanan GUI Şablonu

GUI'nin çalıştırılması sonucunda Şekil 4.19 (a)'da ilk olarak tahıla ait nem ve sıcaklık değerlerinin girileceği kısımları gösteren ara yüz ekranı kullanıcı karşısına çıkmaktadır. Nem ve sıcaklık değerlerinin ara yüzde ilgili bölüme girilip “Çalıştır” butonuna basıldığında tahıl durumuna ait sonuçlar “Sonuç Ekranı” kısmında görülmektedir. Kullanıcı tarafından tahıla ait sıcaklık ve nem değerleri girildikten sonra bu değerler tasarladığımız YSA sınıflandırıcısı ile tahıl depolama durumuna göre arka planda sınıflandırılmakta ve sınıflandırma sonucu kullanıcıya olması gereken tahıl durumu (1=Güvenli (Yeşil), 2=Riskli (Sarı), 3=Tehlikeli (Kırmızı)) “Sonuç Ekranı” kısmında renk kodlarıyla birlikte gösterilmektedir. Şekil 4.19 (b)'de bu duruma ait örnek ekran alıntısı yer almaktadır. Bu sayede geliştirilen Tahıl Kontrol Sistemi ile dış ortamdan anlık olarak elde edilen tahıla ait sıcaklık ve nem değerleri GUI yardımıyla kolaylıkla yorumlanarak sonucu basit bir şekilde kullanıcıya gösterilmekte ve gerektiğinde tahıla zamanında müdahale edilebilmesine imkan tanımaktadır.

(a)



(b)



Şekil 4. 19. Tasarlanan GUI Arayüzü :(a) GUI'nin çalıştırılması sonucu kullanıcı karşısına gelen ilk ekran (b) Sıcaklık ve nem verilerinin kullanıcı tarafından girilmesinden sonraki ekran


5. BÖLÜM

BULGULAR

Bu bölümde Tahıl Kontrol Sistemi ile elde edilen tahıla ait bağıl nem ve sıcaklık verileri kullanılarak Matlab ortamında her bir sınıfa (Güvenli, Riskli, Tehlikeli) ait bağımsız ve ortak sıcaklık, nem grafiklerine yer verilmiştir. Bu grafikler yardımı ile sınıflandırmanın sağlıklı bir şekilde yapılıp yapılmadığı değerlendirilmiştir. Ayrıca tahılın sınıflandırılmasında sıcaklık ve nemden hangisinin daha etkin rol oynayan veri olduğunun tespiti yapılmıştır. Bununla birlikte YSA Tahıl Durum Sınıflandırıcısının oluşturulmasında kullanılan bu verilerin, tahılın Güvenli, Riskli ve Tehlikeli olarak doğru bir şekilde sınıflandırılmasında kullanılabileceğinin literatürdeki tahıl depolama kaynaklarına bakılarak irdelemesi yapılmıştır. Bunun için Kara tarafından hazırlanan “Üründeki Su Oranına ve Belli Sıcaklıklara Göre Bağıl Nem Miktarları” tablosu kullanılmıştır [88]. Bu tablodaki aralık ve değerler, çalışmamızdaki bulgular ile daha hassas olarak karşılaştırılması amacıyla interpolasyon yöntemi ile genişletilmiştir. Daha sonra YSA ile verilerin eğitilmesinde kullanılan 3 farklı eğitim algoritmasının (Traingdm, Trainlm, Trainscg) test aşamasında gösterdikleri başarımlar oranları karşılaştırılmış ve en iyi performans gösteren eğitim algoritması tespit edilmiştir. En iyi performans gösteren eğitim algoritmasına ait ağ başarı oranına yer verilmiştir.


5.1. Tahıl Torbalarına ait Sıcaklık ve Nem Verilerinin Değerlendirilmesi

Aynı tarih aralıklarında “Güvenli”, “Riskli” ve “Tehlikeli” olarak etiketlenen her bir tahıl sınıfına ait sıcaklık ve bağıl (nispi) nem verilerinin grafikler üzerinden değerlendirilmesi yapılmıştır. Şekil 5.1’de “Güvenli” sınıftaki tahıla ait sıcaklık-nem grafiği gösterilmektedir.




Şekil 5. 1. Güvenli Tahıl Sıcaklık –Nem Grafiği

“Riskli” sınıftaki tahıla ait sıcaklık-nem grafiği Şekil 5.2’de gösterilmektedir.




Şekil 5. 2. Riskli Tahıl Sıcaklık –Nem Grafiği

Şekil 5.3’te “Tehlikeli” sınıftaki tahıla ait sıcaklık-nem grafiği gösterilmektedir.




Şekil 5. 3. Tehlikeli Tahıl Sıcaklık –Nem Grafiği

Her bir tahıl sınıfına ait sıcaklık grafiği Şekil 5.4'te belirtilirken her bir tahıl sınıfına ait nem grafiği Şekil 5.5'te yer almaktadır.



Şekil 5. 4. Her bir Tahıl Sınıfına ait Sıcaklık Grafiği



Şekil 5. 5. Her bir Tahıl Sınıfına ait Nem Grafiği

Yukarıda grafiklerde de görüldüğü üzere tahılın sınıflandırılmasında bağıl nemin sıcaklıktan daha belirleyici bir etken olarak karşımıza çıkmaktadır. Sıcaklık değeri tehlikeli tahıl için güvenli ve riskli tahıla göre daha geniş bir aralıkta değişim göstermektedir. Bağıl nem değeri güvenli tahıl için %(42-48) aralığında, riskli tahıl için %(82-85) aralığında, tehlikeli tahıl için %(92-99) aralığında değişkenlik göstermektedir. Sıcaklık değerleri ise güvenli tahıl için (20-23) °C aralığında, riskli tahıl için (21-23,5) °C aralığında, tehlikeli tahıl için ise (21,5-25,5) °C aralığında değişkenlik göstermiştir.

Tahılların bozulmadan depolanabilmeleri için tahıl tanesindeki su içeriğini düşük olması ve depolama sırasında bu düşük tane suyu içeriğinin korunması gerekmektedir. İyi bir tahıl depolama ve depolamanın sağlıklı bir şekilde sürdürülebilirliği için tanelerin yeterince olgun, zedelenmemiş-sağlam; tane suyu içeriğinin %14'ten, sıcaklığın 25°C ve bağıl nem oranında %65'ten düşük olması gerekir. %12, %13 ve %14 oranındaki ürünlerdeki su ve belli sıcaklıklarda olması gerekli bağıl nem miktarları Tablo 5.1'de belirtilmiştir [88].

Tablo 5. 1. Üründeki Su Oranı ve Belirli Sıcaklığa Göre Bağıl Nem [88]

Sıcaklık (°C)	Üründeki Su %12	Üründeki Su %13	Üründeki Su %14
	Bağıl Nem Yüzdeleri (%)		
-1	19	25	32
4.4	25	31	39
10.0	31	38	45
15.6	37	44	51
21.1	43	50	57
26.6	47	55	61
32.2	52	59	65
37.8	56	63	69
43.3	60	66	72
48.9	64	70	74

Bağıl nem yüzdelerine göre üründeki suya ve sıcaklığa bakılarak tahılın durumu hakkında yorum yapabilmek için Tablo 5.1 bilinmeyen ara değerlerin bulunması amacıyla doğrusal (lineer) interpolasyon yöntemi ile genişletilerek detaylandırılmış olup daha geniş bir aralıkta sıcaklık nem değerlerinin değerlendirilmesi sağlanmıştır. Genişletilmiş interpolasyon tablosu Tablo 5.2’de gösterilmektedir. Tablodaki sarı ile gösterilen satırlar alıntı yapılan kaynaktaki (Tablo 5.1) referans değerleridir. Doğrusal interpolasyon yönteminde tespit edilecek ara değerler doğru üzerinde kabul edilerek doğru denklemi kullanılmıştır. Bilinmeyen ara değerler doğru denklemi üzerindeki son değişken-ilk değişken (sarı renkli referans değerleri) arasındaki farka bakılarak hesaplanmıştır.

Bu çalışmada güvenli ve riskli tahıl izlenmeye başlamadan önce üründeki su oranı sırasıyla yaklaşık %13 ve %17 olarak ölçülmüştür. Tahıl izleme sistemi ile elde edilen sıcaklık ve nem değerlerinin (*güvenli tahıl için: bağıl nem değeri % (42-48) aralığında, sıcaklık değeri (20-23) °C aralığında, riskli tahıl için: bağıl nem değeri % (82-85) aralığında, sıcaklık değeri (21-23,5) °C aralığında*) genişletilmiş interpolasyon tablosundaki ürünlerdeki su, sıcaklık ve nispi nem değerleri ile kesiştirilip karşılaştırıldığında bu değerlerin tabloda belirtilen değerler ile paralellik gösterdiği görülmektedir.

Tehlikeli tahıl için ise kontrollü bozma işleminden dolayı başlangıçtaki ürünlerdeki su oranı homojen olarak ölçülememiştir. Tahıl izleme sistemi ile elde edilen sıcaklık ve nem değerlerinin (*tehlikeli tahıl için: bağıl nem değeri %(92-99) aralığında, sıcaklık değeri (21,5-25,5) °C aralığında*) genişletilmiş interpolasyon tablosundaki ürünlerdeki su, sıcaklık ve nispi nem değerleri ile kesiştirilip karşılaştırıldığında ise tablodaki son okunabilen ürünlerdeki su yüzdesi olan %18’in de üzerinde olduğu görülmüştür. Buradan da anlaşılacağı üzere tahılın bozulması sırasında ürünlerdeki su yüzdesi büyük oranda artış göstermektedir.


Yukarıdaki değerlendirmeler neticesinde; bu tez çalışmasında Tahıl Kontrol Sistem ile elde edilen ve YSA tahıl durum sınıflandırıcısında kullanılan verilerin, tahılın Güvenli, Riskli ve Tehlikeli olarak doğru bir şekilde sınıflandırılmasında kullanılabileceğini desteklemektedir.

Tablo 5. 2. Üründeki Su Oranı ve Belli Sıcaklığa Göre Bağlı (Nıspi) Nem (İnterpolasyon Metodu ile Genişletilmiş)

Sıcaklık	Üründeki Su %12	Üründeki Su %13	Üründeki Su %14	Üründeki Su %15	Üründeki Su %16	Üründeki Su %17	Üründeki Su %17,1	Üründeki Su %17,2	Üründeki Su %17,3	Üründeki Su %17,4	Üründeki Su %17,5	Üründeki Su %17,6	Üründeki Su %17,7	Üründeki Su %17,8	Üründeki Su %17,9	Üründeki Su %18
Nispi nem Yüzdeleri %																
-1	19.00	25.00	32.00	38.00	45.00	51.00										
4.4	25.00	31.00	39.00	45.00	53.00	59.00										
10	31.00	38.00	45.00	52.00	59.00	66.00										
15.6	37.00	44.00	51.00	58.00	65.00	72.00										
16	37.44	44.44	51.44	58.44	65.44	72.44	73.14	73.84	74.54	75.24	75.94	76.64	77.34	78.04	78.74	79.44
16.5	37.98	44.98	51.98	58.98	65.98	72.98	73.68	74.38	75.08	75.78	76.48	77.18	77.88	78.58	79.28	79.98
17	38.53	45.53	52.53	59.53	66.53	73.53	74.23	74.93	75.63	76.33	77.03	77.73	78.43	79.13	79.83	80.53
17.5	39.07	46.07	53.07	60.07	67.07	74.07	74.77	75.47	76.17	76.87	77.57	78.27	78.97	79.67	80.37	81.07
18	39.62	46.62	53.62	60.62	67.62	74.62	75.32	76.02	76.72	77.42	78.12	78.82	79.52	80.22	80.92	81.62
18.5	40.16	47.16	54.16	61.16	68.16	75.16	75.86	76.56	77.26	77.96	78.66	79.36	80.06	80.76	81.46	82.16
19	40.71	47.71	54.71	61.71	68.71	75.71	76.41	77.11	77.81	78.51	79.21	79.91	80.61	81.31	82.01	82.71
19.5	41.25	48.25	55.25	62.25	69.25	76.25	76.95	77.65	78.35	79.05	79.75	80.45	81.15	81.85	82.55	83.25
20	41.80	48.80	55.80	62.80	69.80	76.80	77.50	78.20	78.90	79.60	80.30	81.00	81.70	82.40	83.10	83.80
20.5	42.34	49.34	56.34	63.34	70.34	77.34	78.04	78.74	79.44	80.14	80.84	81.54	82.24	82.94	83.64	84.34
21	42.89	49.89	56.89	63.89	70.89	77.89	78.59	79.29	79.99	80.69	81.39	82.09	82.79	83.49	84.19	84.89
21.1	43.00	50.00	57.00	64.00	71.00	78.00	78.70	79.40	80.10	80.80	81.50	82.20	82.90	83.60	84.30	85.00
21.5	43.29	50.36	57.29	64.36	71.29	78.36	79.06	79.76	80.46	81.16	81.86	82.56	83.26	83.96	84.66	85.36
22	43.65	50.82	57.65	64.82	71.65	78.82	79.52	80.22	80.92	81.62	82.32	83.02	83.72	84.42	85.12	85.82
22.5	44.01	51.27	58.02	65.27	72.02	79.27	79.97	80.67	81.37	82.07	82.77	83.47	84.17	84.87	85.57	86.27
23	44.38	51.73	58.38	65.73	72.38	79.73	80.43	81.13	81.83	82.53	83.23	83.93	84.63	85.33	86.03	86.73
23.5	44.74	52.18	58.74	66.18	72.74	80.18	80.88	81.58	82.28	82.98	83.68	84.38	85.08	85.78	86.48	87.18
24	45.10	52.64	59.11	66.64	73.11	80.64	81.34	82.04	82.74	83.44	84.14	84.84	85.54	86.24	86.94	87.64
24.5	45.47	53.09	59.47	67.09	73.47	81.09	81.79	82.49	83.19	83.89	84.59	85.29	85.99	86.69	87.39	88.09
25	45.83	53.55	59.84	67.55	73.84	81.55	82.25	82.95	83.65	84.35	85.05	85.75	86.45	87.15	87.85	88.55
25.5	46.20	54.00	60.20	68.00	74.20	82.00	82.70	83.40	84.10	84.80	85.50	86.20	86.90	87.60	88.30	89.00
26	46.56	54.45	60.56	68.45	74.56	82.45	83.15	83.85	84.55	85.25	85.95	86.65	87.35	88.05	88.75	89.45
26.5	46.92	54.91	60.93	68.91	74.93	82.91	83.61	84.31	85.01	85.71	86.41	87.11	87.81	88.51	89.21	89.91
26.6	47.00	55.00	61.00	69.00	75.00	83.00	83.70	84.40	85.10	85.80	86.50	87.20	87.90	88.60	89.30	90.00
27	47.35	55.29	61.28	69.21	75.21	83.14	83.84	84.54	85.24	85.94	86.64	87.34	88.04	88.74	89.44	90.14
27.5	47.80	55.64	61.64	69.48	75.48	83.32	84.02	84.72	85.42	86.12	86.82	87.52	88.22	88.92	89.62	90.32
28	48.24	56.00	62.00	69.75	75.75	83.50	84.20	84.90	85.60	86.30	87.00	87.70	88.40	89.10	89.80	90.50
28.5	48.69	56.36	62.36	70.02	76.01	83.68	84.38	85.08	85.78	86.48	87.18	87.88	88.58	89.28	89.98	90.68
29	49.14	56.71	62.71	70.28	76.28	83.86	84.56	85.26	85.96	86.66	87.36	88.06	88.76	89.46	90.16	90.86
29.5	49.58	57.07	63.07	70.55	76.55	84.03	84.73	85.43	86.13	86.83	87.53	88.23	88.93	89.63	90.33	91.03
30	50.03	57.43	63.43	70.82	76.82	84.21	84.91	85.61	86.31	87.01	87.71	88.41	89.11	89.81	90.51	91.21
30.5	50.47	57.78	63.78	71.09	77.08	84.39	85.09	85.79	86.49	87.19	87.89	88.59	89.29	89.99	90.69	91.39
31	50.92	58.14	64.14	71.35	77.35	84.57	85.27	85.97	86.67	87.37	88.07	88.77	89.47	90.17	90.87	91.57
31.5	51.37	58.50	64.50	71.62	77.62	84.75	85.45	86.15	86.85	87.55	88.25	88.95	89.65	90.35	91.05	91.75
32	51.81	58.86	64.85	71.89	77.89	84.93	85.63	86.33	87.03	87.73	88.43	89.13	89.83	90.53	91.23	91.93
32.2	52.00	59.00	65.00	72.00	78.00	85.00	85.70	86.40	87.10	87.80	88.50	89.20	89.90	90.60	91.30	92.00
32.5	52.21	59.21	65.21	72.21	78.21	85.21	85.91	86.61	87.31	88.01	88.71	89.41	90.11	90.81	91.51	92.21
33	52.57	59.57	65.57	72.57	78.57	85.57	86.27	86.97	87.67	88.37	89.07	89.77	90.47	91.17	91.87	92.57
33.5	52.93	59.93	65.93	72.92	78.93	85.93	86.63	87.33	88.03	88.73	89.43	90.13	90.83	91.53	92.23	92.93
34	53.29	60.28	66.28	73.28	79.29	86.28	86.98	87.68	88.38	89.08	89.78	90.48	91.18	91.88	92.58	93.28
34.5	53.64	60.64	66.64	73.64	79.64	86.64	87.34	88.04	88.74	89.44	90.14	90.84	91.54	92.24	92.94	93.64
35	54.00	61.00	67.00	73.99	80.00	87.00	87.70	88.40	89.10	89.80	90.50	91.20	91.90	92.60	93.30	94.00
35.5	54.36	61.35	67.35	74.35	80.36	87.35	88.05	88.75	89.45	90.15	90.85	91.55	92.25	92.95	93.65	94.35
36	54.71	61.71	67.71	74.71	80.71	87.71	88.41	89.11	89.81	90.51	91.21	91.91	92.61	93.31	94.01	94.71
36.5	55.07	62.07	68.07	75.07	81.07	88.07	88.77	89.47	90.17	90.87	91.57	92.27	92.97	93.67	94.37	95.07
37	55.43	62.43	68.42	75.42	81.43	88.43	89.13	89.83	90.53	91.23	91.93	92.63	93.33	94.03	94.73	95.43
37.5	55.78	62.78	68.78	75.78	81.78	88.78	89.48	90.18	90.88	91.58	92.28	92.98	93.68	94.38	95.08	95.78
37.8	56.00	63.00	69.00	76.00	82.00	89.00	89.70	90.40	91.10	91.80	92.50	93.20	93.90	94.60	95.30	96.00
43.3	60	66	72													
48.9	64	70	74													

5.2. Eğitim Aşamasında Elde Edilen Sonuçların Değerlendirilmesi

YSA Tahıl Durum Sınıflandırıcısı ile toplamda 240.000 verinin eğitiminde kullanılan 3 farklı eğitim algoritması (Traingdm, Trainlm, Trainsrc) için elde edilen ağ eğitim performans grafikleri Şekil 5.6'da gösterilmektedir.



Şekil 5. 6. Ağ Eğitim Performans Grafikleri : (a) Traingdm Performans Grafiği (b) Trainlm Performans grafiği (c) Trainscg Performans Grafiği

Ağın en iyi doğrulama performansı ortalama kare hatası (MSE) “Traingdm” algoritması için 0.0014943, “Trainlm” algoritması için 0,0014942, “Trainscg” algoritması için ise 0,0014399 olduğunda bulunmuştur. Bu en iyi doğrulama performanslarına ait çevrim sayılarına ise sırasıyla “Traingdm” algoritması için 1687, “Trainlm” algoritması için 18, “Trainscg” algoritması için 41 olduğunda ulaşılmıştır. 3 farklı eğitim algoritması için regresyon analizi yapıldığında ise doğrulama test ve tüm değerler için R değeri yaklaşık 0.99 olarak tespit edilmiştir. Buradaki R değeri iki değişken arasındaki doğrusal ilişkiyi ifade etmekte olup olması gereken bağımsız değişkenin (Target) elde edilen bağımlı değişkene (Output) göre ilişkisini açıklamayı amaçlar.

5.3. Test Aşamasında Elde Edilen Sonuçların Değerlendirilmesi

3 farklı eğitim algoritması için test aşamasında kullanılan Güvenli, Riskli ve Tehlikeli tahıla ait eğitim verilerinden farklı olarak toplamda 60.000'er veriden elde edilen simülasyon sonuçları kullanılarak eğitim algoritmalarının tahılın sınıflandırılmasındaki başarı oranları tespit edilmiştir. Başarı oranlarının tespitinde her bir algoritma için Tablo 5.3'te gösterilen hesaplama yöntemi özet olarak gösterilmiştir.

Tablo 5. 3. YSA Özet Başarı Tablosu


Sıra No	Sıcaklık	Nem	Olmaması Gereken	Test Sonucu	Fark	Başarı Yüzdesi
1	22,37	47,53	1	1,00	0,00%	100,00%
2	22,24	47,53	1	1,00	0,00%	100,00%
3	22,23	47,53	1	1,00	0,00%	100,00%
4	22,24	47,50	1	1,00	0,00%	100,00%
5	22,25	47,53	1	1,00	0,00%	100,00%
6	22,23	47,56	1	1,00	0,00%	100,00%
7	22,34	47,04	1	1,00	0,00%	100,00%
8	22,32	47,22	1	1,00	0,00%	100,00%
9	22,28	47,44	1	1,00	0,00%	100,00%
10	22,29	47,51	1	1,00	0,00%	100,00%
20000	23,17	46,14	1	1,00	0,00%	100,00%
20001	22,52	85,84	2	2,20	9,89%	90,11%
20002	22,61	85,59	2	2,15	7,65%	92,35%
20003	22,62	85,53	2	2,14	7,19%	92,82%
20004	22,64	85,45	2	2,13	6,47%	93,54%
20005	22,66	85,43	2	2,13	6,25%	93,75%
20006	22,66	85,37	2	2,11	5,75%	94,26%
20007	22,68	85,21	2	2,09	4,26%	95,74%
20008	22,70	85,26	2	2,10	4,80%	95,20%
20009	22,69	85,40	2	2,12	6,06%	93,94%
20010	22,69	85,38	2	2,12	5,80%	94,20%
40000	23,30	84,57	2	1,98	1,18%	98,82%
40001	23,48	94,73	3	2,95	1,62%	98,38%
40002	23,54	94,60	3	2,95	1,69%	98,31%
40003	23,56	94,48	3	2,95	1,77%	98,23%
40004	23,57	94,46	3	2,95	1,78%	98,22%
40005	23,56	94,40	3	2,95	1,82%	98,18%
40006	23,60	94,41	3	2,95	1,81%	98,19%
40007	23,56	94,34	3	2,94	1,85%	98,15%
40008	23,59	94,32	3	2,94	1,87%	98,13%
40009	23,57	94,35	3	2,94	1,85%	98,15%
40010	23,58	94,40	3	2,95	1,82%	98,18%
59998	24,86	98,69	3	2,99	0,37%	99,63%
59999	24,86	98,69	3	2,99	0,37%	99,63%
60000	24,86	98,68	3	2,99	0,37%	99,63%
ORTALAMA						98,99%

Tablo 5.3'te de belirtildiği üzere; test sonucu ile olması gereken değer arasındaki farkın mutlak değeri alınarak bu değerın olması gereken değere bölünmesi sonucu elde edilen değer yüzde olarak fark sütununa yazılmıştır. Burada olması gereken değer ile test sonucu arasındaki farkın yüzde cinsinden görülmesi amaçlanmıştır. Daha sonra elde edilen yüzde cinsinden fark değeri %100'den çıkarılarak her bir test sonucunun başarı yüzdesi hesaplanmıştır. Son olarak da 60.000 adet veriyi içeren test sonucuna ait başarı yüzdelerinin ortalaması alınarak ağın başarı oranı hesaplanmıştır. Her bir eğitim algoritması için hesaplanan başarı oranları Tablo 5.4'te gösterilmiştir.

Tablo 5. 4. Her Bir Eğitim Algoritması için Elde Edilen Başarı Yüzdeleri

Kullanılan Eğitim Algoritması	Başarı Yüzdesi %
Traingdm	98,9924
Trainscg	98,9912
Trainlm	98,9855

Tablo 5.4'te görüldüğü üzere en iyi başarı oranı “Traingdm” algoritması kullanıldığında elde edilmiştir. En iyi performansı gösteren “Traingdm” algoritması için başarı oranını gösterir tabloya ait veriler kullanılarak Matlab ortamında ağ başarı oranı grafiği çizdirilmiş olup Şekil 5.7'de gösterilmektedir. Test sonucu ile olması gereken sınıf arasındaki en büyük farklılıklar “2” ile numaralandırılmış riskli tahılta meydana gelmiştir. Riskli tahılı “3” ile numaralandırılan tehlikeli tahıl ve sonrasında “1” ile numaralandırılan güvenli tahıl takip etmiştir. En doğru sonuçlar “1” ile numaralanan güvenli tahılta elde edilmiştir.



Şekil 5. 7. Ağ Başarı Oranı Grafiği

6. BÖLÜM

TARTIŞMA, SONUÇ VE ÖNERİLER BÖLÜMÜ

6.1 Tartışma, Sonuç

TMO bünyesinde kullanılmakta olan Tahıl Torbalama Sistemlerindeki mevcut Tahıl Kontrol Sistemi yerine kablolu sensör düğümleri ile düşük maliyetli, başarımlı oranı yüksek, tahıl durumunun sürekli olarak izlenebildiği yeni bir Tahıl Kontrol Sistemi tasarlanmıştır. Yeni tasarlanan Tahıl Kontrol Sistemi ile mevcut sisteme ait dışa bağımlılık, insan kaynaklı hataların meydana gelmesi gibi eksikliklerin önüne geçilmiştir. Bununla birlikte; tahılın durumunu izlemek için mevcut Tahıl Kontrol Sisteminde kullanılan CO₂ oranı yerine, başlıca tahıl depolama parametreleri olan sıcaklık ve nem değerleri kullanılmaktadır. Bu sayede mevcut sisteme göre daha doğru ve güvenilir sonuçlar elde edilebilmektedir.


Bu çalışmada Matlab nntool kullanılarak YSA ile yapılan sınıflandırmada 3 farklı kategorideki tahıl sürekli olarak izlenmiş olup sıcaklık verisindeki değişimlerin nem verisindeki değişimlere oranla çok daha az olduğu, nem verisinin sıcaklık verisine göre daha belirgin (ayrıt edilebilir) sonuçlar verdiği görülmüştür. Bununla birlikte 3 farklı eğitim algoritması kullanılarak yapılan sınıflandırmada çok büyük farklılıklar olmamakla birlikte en iyi performansın “Traingdm” algoritmasında olduğu görülmüştür.

Tahıl Kontrol Sistem ile elde edilen sıcaklık ve nem verileri arka planda YSA ile tahıla ilişkin durum sınıflandırılması yapıldıktan sonra Matlab GUI ile kolaylıkla yorumlanarak sonucun basit bir şekilde kullanıcıya gösterilmesi sağlanmaktadır. Bu sayede gerektiğinde tahıla zamanında müdahale yapılmakta olup ürün kaybı gibi istenmeyen durumların önüne geçilmektedir.

6.2. Öneriler

Bu tez çalışması ile bu tez çalışmasından faydalanılarak aşağıda bahsedilen sistemler geliştirilebilir;

➤ Günümüz tahıl depolama sistemlerinin birçoğunda (silo, yatay depolar, vb.) depo içerisindeki tahılın durumu sadece sıcaklık parametresine göre değerlendirilmekte olup bu depolara tahılın sıcaklığının sürekli olarak izlenebildiği sıcaklık izleme sistemleri kurulmaktadır. Silo, yatay depo vb. depolama sistemlerinde de tahılın durumunun daha güvenilir ve doğru bir şekilde tespit edebilmek adına gelecekte depo içerisinde nemin de ölçülebildiği izleme sistemlerinin tasarımının sağlanması gerekmektedir. Şekil 6.1’de mevcut depolama sistemlerinde kullanılan sıcaklık izleme sistemlerine ait şematik gösterim belirtilmiştir.



Şekil 6. 1. Mevcut Depolama Sistemlerinde Kullanılan Sıcaklık İzleme Sistemi

➤ Bu tez çalışmasında tahılın sınıflandırılması için kullanılan prototip tahıl torbaları oda sıcaklığında izlenmiştir. Tasarladığımız Tahıl Kontrol Sistemi, daha büyük bir bütçeyle yaklaşık 60 metre uzunluğunda ve 2,74 metre çapındaki gerçek tahıl torbaları kullanılarak doğal çevre koşullarında test edilebilir ve geliştirilebilir. Bu çalışmada geliştiren sistem Türkiye’deki büyük çaplı depolarda (silo, yarı mekanik depolar, mekanize ufki depolar, vb.) da test edilerek uygulanabilirliği görülebilir.

- Bu çalışmada tasarlanan Tahıl Kontrol Sisteminde yerel ağ kullanıldığından ağın kullanılabilirliği kablosuz modem kapsamı kadardır. Büyük depo sistemlerinde kablosuz modem içerisinde sabit IP adresi ve SIM kart kullanılarak sistemin internet üzerinden de kullanımı sağlanabilir ve bu sayede depolardaki tahılın durumu sürekli olarak istenilen her yerden izlenebilir.
- Tez kapsamında kullanılan Raspberry Pi 3 cihazının dış ortamda enerji ihtiyacının sürekli olarak karşılanabilmesi için güneş enerjisi sistemlerinden yararlanılabilir.
- Tez kapsamında kullanılan 2 farklı ara yüz (Veri İzleme Ara Yüzü ve Matlab GUI Yorumlama Ara Yüzü) tek bir ara yüz altında birleştirilerek kullanım kolaylığı sağlanabilir.
- Tahılın sınıflandırılmasında bu çalışmada YSA tekniği kullanılmıştır. Gelecekte yapılacak çalışmalarda bu yöntem dışında Destek Vektör Makineleri, En Yakın Komşu ve Bayes gibi diğer sınıflandırma teknikleri de kullanılarak söz konusu bu teknikler hakkında kıyaslama yapılabilir.
- Ülkemizde çiftçiliğin ve tarımın geliştirilmesi adına toprak ve seraların izlenmesi gibi tarımsal uygulamalarda yeni tasarlanan bu sistemden faydalanabileceği gibi geliştirilerek bitkilerin sınıflandırılması, yabancı otların mahsullerden ayırt edilmesi, bitki hastalıklarının teşhis edilmesi, tahılın verimlilik miktarının belirlenmesi gibi tarımsal alandaki YSA uygulamalarında da kullanılabilir.

KAYNAKLAR

1. Akyildiz I.F., Su W., Sankarasubramaniam Y., Cayirci E., 2002. Wireless sensor networks: a survey. **Computer Networks**, **38**(4):393-422.
2. Dilay Y., Soy H., Bayrak M., 2012. Employment of the wireless sensor networks in precision agriculture and investigation of the application areas. **Iğdır Univ. J. Inst. Sci & Tech.**, **2**(2, Sp: A): 21-26.
3. Zhang Y.,2011. Design of the node system of wireless sensor network and its application in digital agriculture. International Conference on Computer Distributed Control and Intelligent Environmental Monitoring (CDCIEM), pp: 29-35.
4. Toprak Mahsulleri Ofisi. (**Web Sitesi** : <http://www.tmo.gov.tr>), (Erişim tarihi: Haziran 2018).
5. Bartosik R., 2012. An inside look at the silobag system. 9th Int. Conf. on Controlled Atmosphere and Fumigation in Stored Products, Antalya, Turkey, 2012, pp. 117-128.
6. Bartosik R., Cardoso L., 2008. Early detection of spoiled grain stored in hermetic plastic bags(silo-bags) using CO₂ monitoring. 8th Int. Conf. on Controlled Atmosphere and Fumigation in Stored Products, Chengdu, China, 2008.
7. Bartosik R., Cardoso L., Albino J., Busato P., 2013. CO₂ monitoring of grain stored in silobag through a web application. EFITA-WCCA-CIGR Conference on Sustainable Agriculture through ICT Innovation, 2013.
8. Acu A., 1989. İzmir ili pamuk işletmelerinde çığitin depolanmasında bozulmalara bağlı olarak ortaya çıkan yağ miktarı üzerinde azalmaya yol açan değişiklikler üzerine bir araştırma. Tarım Orman Köy İşleri Bakanlığı, İzmir İl Kontrol Laboratuvarı Müdürlüğü, Yayın No: 33, İzmir, 13 s.
9. Şehirali, S., 1989. Tohumluk ve Teknolojisi. Ankara Üniv. Basım Evi, Ankara, 330 s.
10. Jones D., P. Shelton, 1994. Management to maintain stored grain quality. Nebraska State Univ. Cooperative Extension Service, Institute of Agriculture and Natural Researces, 8 p.

11. Shelton D., K.J. Jarvi, D. Jones, 1998. Initial condition determines quality of stored grain. NebGuide, University of Nebraska Cooperative Extension Service, Nebraska, 3p.
12. Michael D., 1999. Finite Element Modeling of Stored Grain Ecosystem and Alternative Pest Control Techniques. Purdue University, Doktora Tezi, 121p.
13. Gümüşkesen A.S., 1999. Bitkisel yağ teknolojisi. Asya Tıp Yayıncılık Ltd.Şti, İzmir, 2: 1-15.
14. Hall C.W. 1980. Drying and Storage of Agricultural Crops. The AVI Publishing Company Inc, USA, 381 p.
15. Kreyger J., 1978. Drying and Storing Grains Seeds and Pulses in Temperate Climates. Institute for Storage and Processing of Agricultural Produce, Publicatie 205, Holland.
16. Proctor D.L., 1994. Grain Storage Techniques Evolution and Trends in Developing Countries. FAO Agricultural Service Bulletin No 109, Roma 277 p.
17. Hellevang K.J., 1990. Crop storage management. NDSU, Extension Service, North Dakota, USA, 4p.
18. Brandenburg N.R., J.W. Simons, L. Smith, 1961. Seeds. The US Department of Agriculture, Washington DC.USA, 295-453.
19. Noyes R.T., B.L. Clary, G.W. Cuperus, 1998. Maintaining Quality of Stored Grain by Aeration. Oklahoma State Univ. Extension Service Division of Agricultural Science and Natural Resources, USA.
20. Gül, H. ve Özçelik, S., 2000. Hububatlarda mikrobiyal bulaşma ve bozulmalar, **Gıda Dergisi**, **26** (1): 33-39.
21. Özkaya, H. ve Özkaya, B., 2005. Öğütme Teknolojisi. Sim Matbaacılık Limited Şirketi, Ankara, 757 s.
22. Hoseney, R.C., 1986. Principles of Cereal Science and Technology. American Association of Cereal Chemists, Inc. St.Paul, Minnesota, 378 p.
23. Kent, N.L., 1982. Technology of Cereals. Pergamon Press, Third Edition, U.S.A, 221 p.

24. Erbaş M., Durak A.N., Arslan S., “Tahıl Depolamada Depolamanın Temel Prensipleri”, Akdeniz Üniversitesi Mühendislik Fakültesi Gıda Mühendisliği Bölümü. (Web Sitesi: www.millermagazine.com/tahil-depolamada-zararlarin-olusum-mekanizmaları-ve-depolamanin-temel-prensipleri/.html), **Miller Değirmenci Dergisi**, (Erişim Tarihi: Haziran 2018).
25. Tekin A.B., Demirel Ç., Örün Ç., “Tarımda Kablosuz Ağlar”, Ege Üniversitesi, Ziraat Fakültesi, Tarım Makinaları Bölümü, İzmir.
26. Romanov, V., Galelyuka, I., Sarakhan, Y., 2015. Wireless sensor networks in agriculture. Intelligent Computing and Information Systems (ICICIS), IEEE Seventh International Conference on, 77-80.
27. Baggio., A., 2005. Wireless sensor networks in precision agriculture. ACM Workshop on Real-World Wireless Sensor Networks (REALWSN 2005), Stockholm, Sweden: 1567-1576.
28. Ayala, M. Toledano., Ruiz, G. Herrera., Soto-Zarazua, M. Genaro., Rivas-Araiza, A.Edgar., Turijilo, B.Rey, Porras-Trejo, E.Rafael., 2011. Long-range wireless mesh network for weather monitoring in unfriendly geographic conditions.**Sensors**, **11**(7): 7141-7161.
29. Shinghal K., Noor D., Srivastava D., Singh D., 2010. Wireless sensor networks in agriculture: for potato farming. **International Journal of Engineering Science**, **2**: 3955-3963.
30. Lea-Cox, Kantor, J.D, Anhalt, G., Ristvey, J., Ross, A., D.S.,2007. A wireless sensor network for the nursery and greenhouse industry. Southern Nursery Association Research Conference, Vol:52.
31. Morais, R., Cunha, J.B., Cordeiro, M., Serodio,C., Salgado, P., Couto, C., 1996. Solar data acquisition wireless network for agricultural applications. Proceedings of the 19th IEEE Convention of Electrical and Electronics Engineers in Israel, Jerusalem, Israeli, November 5–6. pp. 527– 530.
32. Özköse H., 2014. Makineler Arası Haberleşme (M2M) ve Türkiye için Düzenleyiciler. Bilgi Teknolojileri ve İletişim Kurumu, Bilişim Uzmanlığı Tezi, Ankara, 173 s.

33. Ribeiro, A., Garcia-Perez, L., Garcia-Alegre, Guinea, M.C., 2003. A friendly man-machine visualization agent for remote control of an autonomous tractor GPS guided. The Proceedings of the 4th European Conference in Precision Agriculture, June 14–19, Berlin, Germany.
34. Dayıoğlu M.A., Uğur F., Türker U., 2016. Seralarda nesnelerin interneti teknolojisinin uygulanması: tasarım ve prototip geliştirme. **Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi**, **33** (Ek sayı): 52-60.
35. Simon, H. A., 1983. Why should machines learn?, pp-25-37. In: Machine learning: An artificial intelligence approach (Eds. Michalski, R.S., Carbonell, J.G., Mitchell, T.M.), Springer, California.
36. Nilsson, N. J., 2009. The quest for artificial intelligence: a history of ideas and achievements. Cambridge University Press Cambridge, New York, 539 pp.
37. Alpaydın, E., 2013. Yapay öğrenme, 2nd ed., Boğaziçi Üniversitesi Yayınevi İstanbul, 486 s.
38. Öztemel, E., 2016. Yapay Sinir Ağları. Papatya Bilim, Üniversite Yayıncılığı, İstanbul, 232 s.
39. Langley, P., 1996. Elements of Machine Learning, Morgan Kaufmann, 419 s.
40. Mohri, M., Rostamizadeh, A. ve Talwalkar, A., 2012. Foundations of Machine Learning, The MIT Press, 397 pp.
41. Mitchell, T. M., 1997. Machine Learning, 1st Edition, McGraw-Hill Science/Engineering/Math, 400 pp.
42. Alpaydın, E., 2014. Introduction to Machine Learning, MIT Press, 400 pp.
43. Harrington, P., 2012. Machine Learning in Action, 1st Edition, Manning Publications, 347 pp, Shelter Island, NY.
44. Blum, A., 2007. Machine learning theory. (**Web page:** <https://www.cs.cmu.edu/~avrim/Talks/mlt.pdf>), (Erişim Tarihi: Haziran 2018).
45. Domingos, P., 2012. A few useful things to know about machine learning. **Communications of the ACM**, **55** (10): 78–87.
46. Kartal E., 2015. Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 135 s.

47. Schapire, R., 2008. COS 511: Theoretical machine learning. (Web page: http://www.cs.princeton.edu/courses/archive/spr08/cos511/scribe_notes/0204.pdf), (Eriřim Tarihi: Haziran 2018)
48. Camastra, F. ve Vinciarelli, A., 2008. Machine Learning for Audio, Image and Video Analysis: Theory and Applications. Springer-Verlag London, 561 pp.
49. Brownlee, J., 2013. A tour of machine learning algorithms. (Web page: <https://machinelearningmastery.com/a-tour-of-machine-learning-algorithms/>), (Eriřim Tarihi: Haziran 2018).
50. Murphy, K. P., 2012. Machine Learning: A Probabilistic Perspective. Massachusetts Institute of Technology, 1054 pp.
51. Donalek, C., 2011. Supervised and unsupervised learning. (Web Page: http://www.astro.caltech.edu/~george/aybi199/Donalek_Classif.pdf), (Date accessed: April 2018).
52. Hastie, T., Tibshirani, R. ve Friedman, J., 2008. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer-Verlag, London, 745 pp.
53. Kotsiantis, S. B., Zaharakis, I. D. ve Pintelas, P. E., 2006. Machine learning: a review of classification and combining techniques. **Artificial Intelligence Review**, **26** (3):159–190.
54. Kotsiantis, S. B., 2007. Supervised machine learning: A review of classification techniques. **Informatica**, **31** (3), 249–268.
55. Alpaydın, E., 2004. Introduction to machine learning, pp:105-128. In: Methods in Molecular Biology (Eds. Walker, J.M.). Springer, Hatfield, Hertfordshire, UK.
56. Bishop, C. M., 2007. Pattern Recognition and Machine Learning, Springer, Singapur, 738 pp.
57. Çakır, M., 2005. Firma Başarısızlığının Dinamiklerinin Belirlenmesinde Makina Öğrenmesi Teknikleri: Ampirik Uygulamalar ve Karşılaştırmalı Analiz. Türkiye Cumhuriyet Merkez Bankası İstatistik Genel Müdürlüğü, Uzmanlık Yeterlilik Tezi, Ankara, 154 s.
58. Dordinejad, G.G., 2016. Çok Yüzlü Konik Sınıflandırıcılarda Gürbüz Koni Tepe Noktası Tahmini. Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Eskişehir, 74 s.

59. Akkaya, G., 2005. Yapay sinir ağıları ve tarım alanındaki uygulamaları. **Atatürk Üniversitesi Ziraat Fakültesi**, **38(2)**: 195-202.
60. Elmas, Ç., 2016. Yapay Zeka Uygulamaları, 3. Baskı. Seçkin Yayıncılık, 448 s.
61. Haykin, S., 1999. Neural Networks and Learning Machines Third Edition. Pearson Prentice Hall, USA, 889 pp.
62. Taşova, O., 2011. Yapay Sinir Ağları ile Yüz Tanımı. Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İzmir, 65 s.
63. Chen, X., Xun, Y., Li, W. and Zhang, J. 2010. Combining discriminant analysis and neural networks for corn variety identification. **Computers and Electronics in Agriculture**, **71**: 48–53.
64. Aydoğan, H., Altun, A.A., Ozcelik, A.E. 2011. Performance analysis of a turbocharged diesel engine using biodiesel with back propagation artificial neural network. **Energ Educ Sci Tech-A**, **28**: 459-468.
65. Singh, R.K., Chaudhury, S., 2016. Efficient technique for rice grain classification using back-propagation neural network and wavelet decomposition. **The Institution of Engineering and technology Journals**, **10(8)**: 780-787.
66. Li, X., Zhu, W., 2011. Apple grading method base on feature fusion of size, shape and colour. **Procedia Engineering** , **15**: 2885-2891.
67. Majundar, S., Jayas, D.S., 2000. Classification of cereal grain using machine vision : II. colour model. **Trans ASAE**, **43(6)**:1677-1680.
68. Majundar, S., Jayas, D.S., 2000. Classification of cereal grain using machine vision : III. texture model. **Trans ASAE**, **43(6)**:1681-1687.
69. Anami, B.S., Savakar, D.G., Makandar, A., et al, 2005. A neural network model for classification of bulk grain samples based on colour and texture. **Proc. Of Int. Conf. On Cognition and Recognition**, **15**: 2885-2891.
70. Majundar, S., Jayas, D.S., 2000. Classification of cereal grain using machine vision : IV. combined morphology, colour and texture . **Trans ASAE**, **43(6)**:1689-1694.
71. Visen, N.S., Paliwal, J., Jayas, D.S., White, N.D.G., 2002. Specialist neural networks for cereal grain classification. **Biosystems Engineering**, **82**: 151-159.

72. Baykan Ö.K., Babalık, A., Botsalı, F.M., 2005. Yapay sinir ağı kullanarak buğday türü tanınması. 4. Uluslararası İleri Teknoloji Sempozyumu, Konya, Eylül 28-30, Konya.
73. Dubey, B.P., Bhagwat, S.G., Shouche, S.P., Sains, J.K., 2006. Potential of artificial neural networks in varietal identification using morphometry of wheat grains. **Biosystems Engineering**, 95: 61-67.
74. Babalık, A., Baykan, Ö.K., Botsalı, F.M., 2006. Determination of wheat kernel type by using image processing techniques and ANN. The International Conference on Modelling and Simulating, August 28-30, Konya.
75. Taner, A., Tekgüler, A., Sauk, H., 2015. Yapay sinir ağları ile makarnalık buğday çeşitlerinin sınıflandırılması. **Anadolu Tarım Bilimleri Dergisi**, 30 (2015): 51-59.
76. Paliwal, J., Visen, N.S., Jayas, D.S., White, N.D.G., 2003. Comparison of a neural network and a non-parametric classifier for grain kernel identification. **Biosystems Engineering**, 85 (4): 405-413.
77. Vijayakumar N., Maksimovic M., 2015. Raspberry Pi as a sensor web node for home automation. **Computers and Electrical Engineering**, 44: 86-94.
78. direnc.net Sitesi. (Web Sitesi: <https://www.direnc.net/sht10-metal-koruyuculu-kablolu-sicaklik-ve-nem-sensoru>), (Erişim Tarihi: Haziran 2018)
79. Tp-Link Sitesi. (Web Sitesi: https://www.tp-link.com/tr/products/details/cat-4692_M5360.html), (Erişim Tarihi: Haziran 2018)
80. TMO Genel Müdürlüğü, 1990. Alım ve Muhafaza İşleri İzahnamesi.(Web Sitesi: file:///C:/Users/canset.kocer/Downloads/almuh%20(1).pdf), (Erişim tarihi: Haziran 2018).
81. Elgün, A., Ertugay, Z., 1990. Tahıl İşleme Teknolojisi. AtatürkÜniversitesi Ziraat Fakültesi Yayınları, No: 297 Erzurum, 407 s.
82. Gopikrishnan, M., Santhanam, T., 2011. Effect of training algorithms on the accuracy in iris patterns recognition using neural networks. **International Journal of Computer Science and Telecommunications**, 2(7): 10-16.

83. Kefeli, H.C., 2009. Çok katmanlı ileri sürümlü yapay sinir ağlarında standart geri yayılım ve momentum geri yayılım algoritmalarının karşılaştırılması. (Web Sitesi: <http://www.cemkefeli.com/post/2009/03/19/Cok-katmanli-ileri-surumlu-ysada-standart-geri-yayiyim-ve-momentum-geri-yayilim-algoritmalarinin-karsilastirilmesi.aspx>), (Erişim tarihi: Haziran 2018).
84. Sakarya Üniversitesi Bilgi Sistemi. Matlab Kılavuz Neural Network. (Web Sitesi: http://content.lms.sabis.sakarya.edu.tr/Uploads/36957/41696/matlab_k%C4%B1lavuz_neural_network.docx), (Erişim tarihi: Haziran 2018).
85. Çavuşoğlu, M.,A., Becerikli, Y., Karakuzu, C., 2012. Levenberg-Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleşmesi. **Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi**, 5(1).
86. Orozco, J., Garcia C., A., R., “Detecting Pathologies from Infant Cry Applying Scaled Conjugate Gradient Neural Network”, European Symposium on Artificial Neural Network Networks, Bruges, Belgium, 2003.
87. Baghirli, O., 2015. Comparison of Lavenberg-Marquardt, Scaled Conjugate Gradient and Bayesian Regularization BackPropagation Algorithms for Multistep Ahead Wind Speed Forecasting Using Multilayer Perceptron FeedForward Neural Network, Uppsala University Department of Earth Sciences, Campus Gotland, 35s.
88. Kara, K., 1996. Tarla Bitkileri. Atatürk Üniversitesi Ziraat Fakültesi Ders Notları, Yayın No:191, Erzurum.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Canset KOÇER BAYKARA

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 13 Ağustos 1988, Altındağ

Medeni Durumu: Evli

Tel: +90 5061575030

Fax: +90 3124163487

email: kocercanset@gmail.com

Yazışma Adresi: TMO Genel Müdürlüğü, Milli Müdafaa Cad. No:18 Çankaya/Ankara

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Eskişehir Osmangazi Üniversitesi (Elek-Elekt. Müh.)	2012
Lise	Edirne Anadolu Lisesi, Edirne	2006

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2014- Halen	TMO Genel Müdürlüğü	Elektrik Mühendisi
2014	Erciyes Üniversitesi Mekatronik Müh. Bölümü	Araştırma Görevlisi
2013-2014	Amasya Üniversitesi Mekatronik Müh. Bölümü	Araştırma Görevlisi

YABANCI DİL

İngilizce, Almanca, Fransızca

YAYINLAR

1. Kanaan M., Koçer C. , Suveren M., " On The Relationship Between Antenna Parameters And Near-Field Effects For Uwb Implant Body Area Networks ", 8th International Symposium on Medical Information and Communication Technology (ISMICT), , Firenze, ITALYA, 2-4 Nisan 2014, pp.1-5
2. Suveren M., Kanaan M., Kocer C., "INVESTIGATION OF SHADOWING EFFECTS IN ULTRA WIDE BAND IMPLANT BODY AREA NETWORKS", 22nd IEEE Signal Processing and Communications Applications Conference (SIU), TRABZON, TÜRKİYE, 23-25 Nisan 2014, pp.874-877