

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS

GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME TABANLI
BİTKİSEL TARIM ÜRÜNLERİNDE HASTALIK TESPİTİ

Abdullah BÜLGEN

Danışman: Dr. Öğr. Üyesi Funda AKAR

YAPAY ZEKA VE ROBOTİK
ANABİLİM DALI

ERZİNCAN
2024
Her Hakkı Saklıdır.

Kabul ve Onay Sayfası

Dr. Öğr. Üyesi Funda AKAR danışmanlığında, Abdulmuttalip BÜLGEN tarafından hazırlanan bu çalışma 20.03.2024 tarihinde aşağıdaki jüri tarafından Disiplinlerarası Yapay Zeka ve Robotik Anabilim Dalı'nda Yüksek Lisans olarak kabul oybirliği ile kabul edilmiştir.

Başkan: Dr. Öğr. Üyesi Funda AKAR İmza:

Üye : Prof. Dr. Uğur YAVUZ İmza:

Üye : Doç. Dr. Kamil ORMAN İmza:

Yukarıdaki sonuç Enstitü Yönetim Kurulunun / / 20.... tarih ve/..... sayılı kararı ile onaylanmıştır.

Doç. Dr. Kemal Volkan ÖZDOKUR
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, şekil ve tabloların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

Bilimsel Etięe Uygunluk Sayfası

“Görüntü İşleme ve Derin Öğrenme Tabanlı Bitkisel Tarım Ürünlerinde Hastalık Tespiti” isimli “Yüksek Lisans” tezim tarafımca intihal tespit programı ile incelenmiştir. Buna göre tezimde bilimsel etik ihlali ve intihal olarak nitelendirilebilecek herhangi bir durum olmadığını taahhüt ederim.

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir biçimde elde edildiğini; aynı zamanda bu kural ve davranışların gerektirdiğı gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 20/03/2024

(İmza)

Abdulmuttalip BÜLGEN

ÖZET

Yüksek Lisans Tezi

GÖRÜNTÜ İŞLEME VE DERİN ÖĞRENME TABANLI BİTKİSEL TARIM ÜRÜNLERİNDE HASTALIK TESPİTİ

Abdulmuttalip BÜLGEN

Erzincan Binali Yıldırım Üniversitesi
Fen Bilimleri Enstitüsü
Yapay Zeka ve Robotik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Funda AKAR

Küresel ve yerel düzeydeki iklim değişiklikleri ve kuraklık koşulları sürdürülebilir tarım uygulamalarının önemini arttırmıştır. Bu çalışmada, yapay zeka ve derin öğrenme teknolojilerinin, mısır ve buğday gibi tarım ürünlerindeki bitki hastalıklarının tespiti ve ürünlerde oluşabilecek verim kayıplarının önlenmesinde etkili araçlar olarak kullanılabilirliği incelenmiştir. Mısır ve buğdayın büyüme dönemlerinde, bitkilerin sağlığını belirleyen önemli bir faktör de hastalıklı yaprakların tespitidir. Bu çalışmada, mısır için 4.188 adet, buğday için ise 977 adet görüntü kullanılarak yapay zeka tabanlı sınıflandırma modelleri geliştirilmiştir. Mısırdaki "Residual Network (ResNet)" modeli, buğdayda ise "You Only Look Once (YOLO)" modelleri kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Mısır için ResNet50 ile %85,30, ResNet101 ile %94,56 ve ResNet152 ile %94,14 oranında doğruluk sağlanmıştır. Buğdayda ise YOLOv5s ile %68,9 kesinlik ve %70,4 duyarlılık, YOLOv8 ile %95,4 kesinlik ve %88 duyarlılık ayrıca %93,4 mAP50 (ortalama doğruluk) oranlarına ulaşılmıştır. Çalışmada ek olarak ResNet-50/101/152 ve YOLO-v5s/v8 modellerinin karşılaştırmalı analizi sunulmuş, mısır için ResNet101 modelinin ve buğday için YOLOv8 modelinin benzer veri setleriyle kıyaslandığında en yüksek başarı oranlarına ulaşıldığı ortaya konulmuştur.

2024, 110 Sayfa

Anahtar Kelimeler: Buğday Yaprığı Hastalıkları, Derin Öğrenme, Görüntü İşleme, Mısır Yaprığı Hastalıkları, ResNet, Yapay Zeka, YOLO

ABSTRACT

MSc

DISEASE DETECTION IN HERBAL AGRICULTURAL PRODUCTS BASED ON IMAGE PROCESSING AND DEEP LEARNING

Abdulmuttalip BÜLGEN

Erzincan Binali Yıldırım University
Graduate School of Natural and Applied Sciences
Department of Artificial Intelligence and Robotics

Supervisor: Asist. Prof. Dr. Funda AKAR

Climate change and drought conditions at both global and local levels have increased the importance of sustainable agricultural practices. This study examines the applicability of artificial intelligence and deep learning technologies as effective tools for detecting plant diseases in crops such as corn and wheat, and for preventing yield losses that may occur in these crops. During the growth stages of corn and wheat, a significant factor determining the health of plants is the detection of diseased leaves. In this study, artificial intelligence-based classification models were developed using 4,188 images for corn and 977 images for wheat. The "Residual Network (ResNet)" model was employed for corn, while the "You Only Look Once (YOLO)" models were used for wheat to conduct classification processes. For corn, accuracies of 85.30% with ResNet50, 94.56% with ResNet101, and 94.14% with ResNet152 were achieved. For wheat, precision and recall rates of 68.9% and 70.4% with YOLOv5s, 95.4% precision and 88% recall with YOLOv8, and a 93.4% mAP50 (mean average precision) were attained. Additionally, a comparative analysis of ResNet-50/101/152 and YOLOv5s/v8 models was presented, revealing that the ResNet101 model for corn and the YOLOv8 model for wheat achieved the highest success rates when compared with similar datasets.

2024, 110 Pages

Keywords: Artificial Intelligence (AI), Corn Leaf Diseases, Deep Learning, Image Processing, Residual Networks (ResNet), Wheat Leaf Diseases, You Only Look Once (YOLO)

TEŞEKKÜR

Bu akademik yolculuğumun en önemli aşamasında, tezimin hazırlık sürecinde bana değerli bilgileri, derin tecrübeleri ve yol gösterici fikirleriyle ılık tutan, akademik danışmanım Sayın Dr. Öğr. Üyesi Funda AKAR'a sonsuz teşekkürlerimi sunarım. Onun kılavuzluğunda geçen bu süreç, bana sadece bilimsel anlamda değil, kişisel gelişimimde de büyük katkılar sağlamıştır. Bilgeliği ve anlayışı, bu zorlu akademik serüvende benim için bir pusula olmuştur.

Tarım ile uğraşan çiftçi bir ailenin verimli topraklarından yetişen, mühendislik biliminin çeşitli dallarında gelişen bir birey olarak ailemin bana sağladığı sarsılmaz inanç ve destek sayesinde bugünlere ulaştım. Bu uzun ve meşakkatli yolculukta, her zaman yanımda olan, maddi ve manevi desteğini esirgemeyen babam Hasan BÜLGEN'e, sonsuz sevgi ve sabırla beni ayakta tutan annem Servet BÜLGENE'e ve kız kardeşlerime olan minnettarlığımı ifade etmekten onur duyarım.

Hayatımın her döneminde, desteğini esirgemeyen ve ilham kaynağı olan eşim Emine BÜLGEN'e zorlukların üstesinden gelmemde en büyük güç kaynağım olmasından dolayı teşekkür ederim. Ve en özel teşekkürüm, tez yazım sırasında bana neşe dolu mola anları sunan, minik kalpleri ile büyük sevgilerini hissettiren ve varlıkları ile en büyük motivasyon kaynağım olan oğullarım Hasan Can ve Muhammed BÜLGEN'e, Bu zorlu akademik serüven boyunca beni destekleyen herkese, burada ifade edemeyeceğim kadar büyük bir şükran borçluyum. Her birinizin katkısı, bu tezin her bir kelimesinde yaşamaktadır.

Abdullahmuttalip BÜLGEN

Mart, 2024

İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ.....	vii
SİMGELER ve KISALTMALAR	viii
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ	8
2.1. Mısır Konusunda Yapılan Çalışmalar	9
2.2. Buğday Konusunda Yapılan Çalışmalar	14
3. KURAMSAL TEMELLER.....	20
3.1. Tarımsal Üretim	20
3.2. Mısır ve Buğday Yaprak Hastalıkları.....	21
3.3. Yapay Zeka Kullanılarak Mısır ve Buğday Yapraklarından Hastalık Teşhisinin Sürdürülebilirlik Hedeflerine Katkıları	26
3.4. Dijital Tarım Evrimi ve Hassas Tarım	28
3.5. Yapay Zekâ ve Tarihsel Gelişimi.....	29
3.5.1. Antik çağlardan modern çağa yapay zekâ.....	30
3.5.2. Turing testi ve yapay zekânın felsefi temelleri	31
3.5.3. Modern yapay zeka kavramının doğuşu ve gelişimi.....	32
3.5.4. Günümüzde yapay zeka	35
3.6. Tarımda Yapay Zeka Uygulamaları	37
3.7. Makine Öğrenmesi	40
3.7.1. Terminoloji.....	41
3.8. Derin Öğrenme.....	41
3.8.1. Derin öğrenme ile makine öğrenmesi arasındaki ilişki.....	42
3.9. Evrişimli Sinir Ağları	45
3.10. Görüntü İşleme.....	46
3.10.1. Yapay zeka ile gelişen tarımda görüntü işlemenin rolü.....	47

3.11. ResNet ve YOLO'nun Önemi	48
3.12. ResNet Modeli ve Gelişimi.....	49
3.12.1. ResNet modelleri	51
3.12.2. Tarımda ResNet modelinin kullanım alanları.....	53
3.13. YOLO Modeli ve Gelişimi	54
3.13.1. YOLO modelleri	55
3.13.2. Tarımda YOLO modelinin kullanım alanları ve uygulamaları	63
4. MATERYAL ve YÖNTEM.....	66
4.1. Veri Seti.....	66
4.2. Çalışma Ortamı ve Uygulama Geliştirme Süreci	70
4.2.1. ResNet modelleri ve eğitim süreçleri	71
4.2.2. Mısır veri setinin hazırlanması ve eğitim süreci	71
4.2.3. Mısır eğitim sürecinin detayları ve hiper parametre ayarlamaları	71
4.2.4. Buğday tanımlamasında yolo eğitim parametreleri ve değerleri	72
4.2.5. Nesne tespiti için veri seti hazırlığı ve etiketleme süreci	72
4.2.6. Buğday veri setinin genişletilmesi ve zenginleştirilmesi	74
5. BULGULAR	76
5.1. Mısır İçin Bulgular	76
5.2. Mısır için ResNet grafiklerinin bulguları, analizi ve yorumu	76
5.2.1. Mısır için ResNet101 modelinin karşılaştırmalı başarı analizi	80
5.3. Buğday İçin Bulgular	81
5.3.1. Buğday için YOLO grafiklerinin bulguları, analizi ve yorumu	84
5.3.2. YOLO modeli ile bitki yapraklarının sağlık durumunun tespiti	90
5.3.3. Buğday için YOLOv8 modelinin karşılaştırmalı başarı analizi	92
6. SONUÇ ve TARTIŞMA.....	94
7. ÖNERİLER.....	96
KAYNAKLAR	98

ŞEKİLLER LİSTESİ

Sayfa

Şekil 3.1. Yapay zekâ'nın temel bileşenleri.....	30
Şekil 3.2. Yapay zekâ problem modelleme.....	34
Şekil 3.3. Yapay zekâ yöntemleri	40
Şekil 3.4. Makine öğrenmesi ve derin öğrenme genel gösterimi.....	43
Şekil 3.5. ResNet mimarisi	50
Şekil 3.6. Residual fonksiyonu görünümü	51
Şekil 3.7. ResNet'in çeşitli derinliklerdeki versiyonları.....	52
Şekil 3.8. Yolo sürümlerinin zaman çizelgesi.....	57
Şekil 3.9. Yolo'da bağlantı kutusunun görselleştirilmesi.....	58
Şekil 3.10. Yolo v5'in algılama başlığı	58
Şekil 3.11. Yolo v8'in algılama başlığı.....	59
Şekil 3.12. Yolo-v8'in önceki versiyonlarla karşılaştırılması	60
Şekil 3.13. Yolo v8 mimarisi	62
Şekil 3.14. Yolo'nun ana uygulamalarının bibliyometrik ağ görselleştirilmesi	64
Şekil 4. 1. (a) mısır adi pası (b) gri yaprak lekesi (c) yaprak yanıklığı (d) normal verisetindeki mısır sınıfına ait örnek görüntüler	67
Şekil 4. 2. (a) septorya yaprak lekesi (b) çizgi pası-sarı pas (c) normal verisetindeki buğday sınıfına ait örnek görüntüler	69
Şekil 4. 3. Roboflow ile etiketleme işleminin ekran görüntüsü	73
Şekil 4. 4. Veri artırma yöntemleriyle işlenmiş görüntüler.....	75
Şekil 5.1. Resnet50 modelinin eğitim başarımları ve kayıplarının grafiksel gösterimi ..	77
Şekil 5.2. Resnet101 modelinin eğitim başarımları ve kayıplarının grafiksel gösterimi	78
Şekil 5.3. Resnet152 modelinin eğitim başarımları ve kayıplarının grafiksel gösterimi	79
Şekil 5.4. Yolov5 nesne tanıma modelinin eğitim sürecindeki performans metrikleri...	85
Şekil 5.5. Yolov8 nesne tanıma modelinin eğitim sürecindeki performans metrikleri...	87
Şekil 5.6. Yolov8 karışıklık matrisi	88
Şekil 5.7. Yolov8'in yapraklardaki hastalık tespitini gösteren eğitim örneği.....	91

TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Yapay zeka yöntemleri ile tarım araştırmalarına örnekler.....	39
Tablo 3.2. Makine öğrenmesi ve derin öğrenmenin genel karşılaştırılması	44
Tablo 4.1. Mısır verisetinin ayrıntıları	68
Tablo 4.2. Buğday verisetinin ayrıntıları	69
Tablo 4.3. Mısır için ResNet eğitim parametre ve değerleri.....	71
Tablo 4.4. Buğday için YOLO eğitim parametre ve değerleri.....	72
Tablo 5.1. Mısır için ResNet modellerinin test sonuçları	76
Tablo 5.2. Mısır için diğer modellerle ResNet101 karşılaştırılması	80
Tablo 5.3. Buğday için YOLOv5s ve YOLOv8 karşılaştırılması.....	81
Tablo 5.4. Buğday için YOLO model karşılaştırması tablosu	82
Tablo 5.5. YOLOv5s ve YOLOv8 model özetleri arasındaki karşılaştırma.....	84
Tablo 5. 6. Buğday için diğer modellerle YOLOv8 karşılaştırılması	92

SİMGELER ve KISALTMALAR

Simgeler

%	Yüzde
&	and - ve

Kısaltmalar

AI	Artificial Intelligence - Yapay Zeka
Bkz	Bakınız
CNN	Convolutional Neural Network - Evrişimli Sinir Ağları
COCO	Common Objects in Context - Bağlam İçindeki Ortak Nesneler
Conv	Convolutional Layer - Konvolüsyonel Katman
DenseNet	Densely Connected Convolutional Networks - Yoğun Bağlantılı Konvolüsyonel Ağlar
FAO	Food and Agriculture Organization - Gıda ve Tarım Örgütü
FLOPs	Floating Point Operations per Second - Saniyede Yüzer Nokta İşlemleri
GAN	Generative Adversarial Network - Üretici Karşıt Ağlar
GGE-biplot	Genotype plus Genotype-by-Environment biplot - Genotip ve Genotip-Çevre Etkileşimi biplot'u
GPS	Global Positioning System -Küresel Konumlandırma Sistemi
GPU	Graphics Processing Unit - Grafik İşlem Birimi
GridSearchCV	Grid Search Cross Validation - Izgara Arama Çapraz Doğrulama
HLB	Huanglongbing
ILSVRC2015	ImageNet Large Scale Visual Recognition Challenge 2015 ImageNet Büyük Ölçekli Görsel Tanıma Yarışması 2015
IoU	Intersection over Union - Kesişim Birliğin Üzerinde
İHA	İnsansız Hava Araçları
K-Means	K-Means - K-Ortalamlar
K-NN	K-Nearest Neighbors - K-En Yakın Komşular
LibSVM	Library for Support Vector Machines - Destek Vektör Makineleri için Kütüphane
LSTM	Long Short-Term Memory - Uzun Kısa Süreli Bellek
mAP	mean Average Precision - ortalama Hassasiyetin Ortalaması

MÖ	Milattan Önce
NZDL	New Zealand Digital Library - Yeni Zelanda Dijital Kütüphanesi
PCA	Principal Component Analysis - Temel Bileşen Analizi
R-CNN	Region-based Convolutional Neural Networks - Bölge Tabanlı Evrişimli Sinir Ağları
RESNET	Residual Network – Artık Ağ
RF	Random Forest - Rastgele Orman
RFCN	Region-based Fully Convolutional Network - Bölge Tabanlı Tam Evrişimli Ağ
SDG	Sustainable Development Goals -Sürdürülebilir Kalkınma Hedefleri
SLIC	Simple Linear Iterative Clustering - Basit Lineer İteratif Kümeleme
SMOTE	Synthetic Minority Over-sampling Technique - Sentetik Azınlık-Örnekleme Tekniği
SSD	Single Shot Multibox Detector - Tek Atışlı Çok Kutulu Dedektör
SVM	Support Vector Machine - Destek Vektör Makineleri
TMO	Toprak Mahsulleri Ofisi
TÜİK	Türkiye İstatistik Kurumu
UAV	Unmanned Aerial Vehicle
vb	ve benzeri
vd	ve diğerleri
VGG	Visual Geometry Group- Görsel Geometri Grubu
VGG16-BN	VGG16 with Batch Normalization - Batch Normalizasyonlu VGG16
XGBoost	eXtreme Gradient Boosting - Aşırı Gradyan Artırma
YOLO	You Only Look Once – Sadece Bir Kez Bak
ZİHA	Zirai İnsansız Hava Araçları

1. GİRİŞ

Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO, 2009) tarafından yapılan tahminlere göre, 2050 yılına kadar dünya nüfusunun 9,1 milyara ulaşması beklenmektedir. Gelişmekte olan ülkelerde büyük bir nüfus artışının gerçekleşeceği ve şehirleşme sürecinin devam edeceği öngörülmekte ve dünya nüfusunun yaklaşık %70'inin şehirlerde yaşayacağı tahmin edilmektedir. Artan nüfusun gıda ihtiyacını karşılamak için tarımsal üretimin verimli ve sürdürülebilir yöntemlerle geliştirilmesi gerekliliği vurgulanmaktadır. Türkiye İstatistik Kurumu (TÜİK, 2022) tarafından yapılan araştırmalara göre, 2021 yılı itibarıyla Türkiye'nin nüfusu bir önceki yıla göre 1 milyon 65 bin 911 kişi artarak 84 milyon 680 bin 273 kişiye ulaşmış, il ve ilçe merkezlerinde yaşayanların sayısı 78 milyon 908 bin 631 olarak belirlenmiştir. Şehir merkezlerinde yaşayanların oranı %93,2'ye yükselmiştir. Belde ve köylerde yaşayanların oranı ise %6,8'e düşmüştür. 2021 yılı verilerine göre, Türkiye'deki şehir merkezlerinde yaşayan 78 milyon 908 bin 631 kişinin temel gıda, sebze ve meyve ihtiyacı, kırsal kesimde yaşayan 5 milyon 771 bin 642 kişi tarafından karşılanmaktadır. Bu durum, tarım arazilerinin verimli bir şekilde kullanılması ve tarıma teknolojinin entegre edilmesinin önemini artırmakta ve çiftçilerin kaliteli ürünler yetiştirebilmesi gerekliliğini ortaya koymaktadır. Dünya nüfusunun artması, iklim değişiklikleri ve kırsal kesimdeki tarım işgücünün azalması nedeniyle tarımsal ürünlerin verimliliğinin artırılması adına bitki hastalıklarının doğru teşhisi ve etkili zirai mücadele yöntemlerinin kullanılması büyük önem taşımaktadır. Bitkilerdeki hastalıklar, yaprakların gelişimini olumsuz etkileyerek verimi düşürebilmekte ve bitkinin kurumasına neden olabilmektedir. Bu durum, tahıl ve bakliyat bitkilerinin pazara sunumunu azaltabilmekte ve tarım ekonomisine olumsuz etkiler yaratabilmektedir.

Çağımızda karşılaştığımız birçok zorluk, beslenme problemlerini kaçınılmaz kılmaktadır. Bu zorluklar arasında artan dünya nüfusu, salgın hastalıklar, savaşlar, siyasi göçler, iklim değişikliği ve özellikle şehirleşmedeki artış yer almaktadır. Küresel ısınmanın, özellikle tarım alanında gelecekte ciddi sorunlara yol açması beklenmektedir. Teknolojiyi etkili bir şekilde kullanamayan gelişmekte olan ülkeler, bu tür sorunlardan en çok etkilenecek ve tarımsal ürünler için yabancı kaynaklara bağımlı hale geleceklerdir. Bu durum ekonomiyi olumsuz etkileyecek ve gıda fiyatlarının artmasına neden olacaktır.

Bu sorunları ortadan kaldırmak için tarımsal üretime odaklanmak gerekmektedir. Ancak, geleneksel tarım yöntemleriyle uygun olmayan ürün rotasyonu (ekim nöbeti), yanlış gübre kullanımı, bitki yaprak hasatlıklarının tespit edilmemesi ya da tespit edilse dahi yanlış ilaçlama, ormanların yok edilmesi ve toprak erozyonu gibi birçok nedenle tarım alanları giderek azalmaktadır. Bu sorunları en aza indirmek, sürdürülebilirliği sağlamak ve artan talepler ile azalan kaynaklar arasında bir denge kurmak için, her sektörde kullanılan teknoloji tarım sektörüne de yansıtılmalıdır (Rossini vd., 2021). Bu yeni ortaya çıkan dijital teknoloji sayesinde işletmeler, daha iyi performans sergileyerek rekabet avantajı elde edebileceklerdir.

Tarımsal üretim süreçleri, küresel gıda ihtiyacını karşılamada kritik bir rol oynamaktadır. Ancak, bitkisel ürünlerin hastalıklar ve zararlılar tarafından etkilenmesi, bu süreçlerde önemli verim kayıplarına neden olmaktadır. Bu kayıpların önlenmesi hem gıda güvenliğinin sağlanması hem de sürdürülebilir tarım uygulamalarının desteklenmesi açısından büyük önem taşımaktadır. Geleneksel hastalık tespit yöntemleri, genellikle zaman alıcı ve uzman bilgi gerektiren süreçler olduğundan, hastalıkların hızlı ve etkin bir şekilde tespit edilebilmesi için otomatik sistemlere olan ihtiyaç giderek artmaktadır.

Mısır, insan beslenmesi ve hayvancılıkta yem olarak tercih edilmesinin ötesinde, alkol, etanol, şurup, yapıştırıcı, yağ, irmik ve nişasta temelli şekerler gibi çeşitli sanayi ürünlerinin elde edilmesinde de kritik bir hammadde olarak kullanılmaktadır (Akarken ve Taş, 2014; Tarım ve Orman Bakanlığı, 2014).

Buğday, dünya genelinde en önemli gıda mahsullerinden biri olarak kabul edilmekte, ancak üretimini tehdit eden çeşitli hastalıklar mevcuttur. Bu hastalıklar arasında en yaygın olanları, yaprak hastalıklarıdır. Yaprak hastalıkları, buğday bitkisinin yapraklarına, saplarına ve başaklarına zarar vermektedir. Bu zararlar, verimde kayıplara, kalite düşüşlerine ve bazen de tamamen ürün kaybına yol açabilmektedir.

Mısır ve buğday, insan beslenmesi için vitamin ve mineral bakımından zengin kaynaklar olup, hayvan yemi olarak da yüksek besin değerine sahiptir. Bu ürünler, un, yağ ve tatlandırıcı üretiminde endüstriyel olarak önemli rol oynamaktadır. Küresel ve yerel düzeyde meydana gelen iklim değişiklikleri ve artan kuraklık koşulları, sürdürülebilir tarım uygulamalarının önemini artırmıştır. Özellikle, tarım sektöründe yapay zekanın

kullanımı, son yıllarda önemli ölçüde artış göstermiştir. Bitki büyüme dönemlerinde, hastalıklı yaprakların tespiti, bitkinin sağlığı için kritik bir süreçtir. Bu sebeplerle sunulan bu çalışmada hem dünya genelinde hem de Türkiye'de kritik bir tarım ürünü olan mısır ve buğday üzerine yoğunlaşmıştır.

Bu çalışmanın amacı, tarımsal üretimde hastalık tespiti sorununa yönelik olarak, bilgisayar bilimi teknikleriyle geliştirilen yenilikçi bir çözümü sunmak ve bu çözümün etkinliğini farklı deneylerle ortaya koymaktır. Özünde ise görüntü işleme ve derin öğrenme tekniklerini kullanarak mısır ve buğday gibi temel tarım ürünlerinde görülen yaprak hastalıklarının otomatik olarak tespit edilmesi için etkili ve güvenilir bir yöntem geliştirmektir. Bu amaçla, derin sinir ağlarına dayalı iki popüler model olan Residual Networks (ResNet) ve You Only Look Once (YOLO) teknikleri incelenerek, hastalık belirtilerinin doğru bir şekilde sınıflandırılması ve lokalize edilmesi hedeflenmektedir. Önerilen yöntemin, tarımsal verimliliği artırma, hastalıkların yayılmasını önleme ve genel olarak tarım teknolojilerinin ilerlemesine katkı sağlama potansiyeline sahip olduğu düşünülmektedir.

Dünya genelinde artan nüfus ve sınırlı tarım arazileri, tarımsal üretimin verimliliğini ve sürdürülebilirliğini artırmak için yenilikçi çözümler bulunmasını zorunlu kılmaktadır. Bitkisel tarım ürünlerinde hastalık tespiti, ürün kaybını önleme ve hasat verimliliğini artırma açısından kritik bir öneme sahiptir. Geleneksel yöntemler, genellikle zaman alıcı ve uzman bilgisi gerektiren görsel incelemelere dayanmaktadır. Bu yöntemler, geniş tarım alanlarının etkin bir şekilde izlenmesinde yetersiz kalabilmekte ve hastalıkların geç tespit edilmesine neden olabilmektedir.

Görüntü işleme ve derin öğrenme tabanlı yaklaşımlar, bu sorunlara çözüm sunmakta ve hastalık tespitini otomatize etme potansiyeline sahiptir. ResNet ve YOLO gibi modeller, yüksek doğrulukla ve hızla hastalıklı bitki yapraklarını tespit edebilir, bu da erken müdahaleye olanak tanır ve ürün kaybını önemli ölçüde azaltabilir. Bu çalışma, tarım sektöründeki teknolojik yenilikleri ilerletme ve küresel gıda güvenliğine katkıda bulunma potansiyeli taşımaktadır.

Tarımsal üretim, küresel gıda güvenliğinin temel taşıdır. Ancak, bitkisel ürünlerde görülen hastalıklar, dünya çapında tarımsal verimlilik üzerinde ciddi bir tehdit

oluşturmakta ve ekonomik kayıplara neden olmaktadır. Mısır ve buğday gibi temel gıda ürünlerinde yaygın olarak rastlanan yaprak hastalıkları, eğer erken tespit edilemezse, hasat kaybı, ürün kalitesinde düşüş ve dolayısıyla gıda güvenliği üzerinde olumsuz etkiler yaratabilir.

Geleneksel hastalık tespit yöntemleri, genellikle uzmanların görsel incelemelerine dayanır. Bu yöntemler zaman alıcıdır, yüksek maliyetli olabilir ve büyük tarım alanlarının etkin bir şekilde izlenmesi için ölçeklenebilir değildir. Ayrıca, görsel inceleme subjektif olabilir ve erken evre hastalıkların tespiti zorlaşabilir. Bu durum, hastalıkların yayılmasını önlemek için gereken müdahalelerin gecikmesine neden olabilir.

Son yıllarda, görüntü işleme ve derin öğrenme teknikleri, birçok alanda olduğu gibi tarımsal hastalık tespitinde de umut vaat eden sonuçlar göstermiştir. ResNet ve YOLO gibi derin öğrenme modelleri, bitki yapraklarının yüksek çözünürlüklü görüntülerini analiz ederek hastalık belirtilerini otomatik olarak sınıflandırabilir ve lokalize edebilir. Bu teknolojiler, hastalık tespitini hızlandırabilir, objektiflik sağlayabilir ve büyük tarım alanlarının etkin bir şekilde izlenmesini mümkün kılabilir. Ancak, bu modellerin tarımsal uygulamalarda etkin bir şekilde nasıl kullanılacağına dair önemli sorular ve zorluklar bulunmaktadır. Bu zorluklar arasında yeterli eğitim verisi bulunmaması, çeşitli hastalık türlerini doğru bir şekilde sınıflandırma ve lokalize etme kapasitesi ve farklı çevresel koşullarda model performansının tutarlılığı gibi konular yer almaktadır.

Bu çalışma, görüntü işleme ve derin öğrenme tabanlı yöntemlerin, özellikle ResNet ve YOLO modellerinin, mısır ve buğday yaprak hastalıklarının tespitinde nasıl etkili bir şekilde kullanılabileceğini keşfetmeyi amaçlamaktadır. Sorun bildirimini, mevcut zorlukların üstesinden gelme potansiyelini vurgulayarak, bu teknolojilerin tarımsal hastalık tespitinde nasıl bir devrim yaratabileceğini ortaya koymaktadır.

Bu tez çalışması, yedi bölümden oluşmaktadır. İlk bölüm olan "Kaynak Özetleri" bölümü, mısır ve buğday bitkilerinin karşılaştığı çeşitli hastalıkları ve bu hastalıkların tarımsal üretim üzerindeki etkilerini ele almaktadır. Bu kısımda, dünya nüfusunun artışı ve buna paralel olarak gıda ihtiyacının artması bağlamında, mısır ve buğdayın besin değeri ve endüstriyel kullanımı ön plana çıkarılmaktadır. Ek olarak bitkisel üretimdeki verim kayıplarına neden olan yaprak hastalıklarının teşhisi ve mücadele yöntemlerine

odaklanılmakta, bu bağlamda derin öğrenme ve yapay zeka teknolojilerinin kullanımıyla ilgili çeşitli akademik çalışmalar ayrıntılı olarak incelenmektedir. Özellikle, evrişimli sinir ağları, Rastgele Orman ve diğer gelişmiş modellemelerin hastalıkların tespitindeki başarısı ve tarımsal verimlilik üzerindeki olumlu etkileri vurgulanmaktadır. Ayrıca bu tez çalışması, teknolojik yaklaşımların mısır ve buğday gibi temel tarım ürünlerinin verimliliğini artırarak küresel gıda güvenliği ve sürdürülebilir tarım pratiğine katkı sağlayabileceğini ortaya koymaktadır.

"Kuramsal Temeller" başlıklı bölümde, tarımsal üretim, mısır ve buğday yaprak hastalıkları, yapay zeka kullanımının sürdürülebilirlik hedeflerine katkıları ve dijital tarımın evrimi ayrıntılı olarak ele alınmaktadır. Bu bölümde, mısır ve buğdayın önemi vurgulanırken, hastalık tespitinde yapay zeka ve özellikle derin öğrenme teknolojilerinin potansiyeli tartışılmaktadır. ResNet ve YOLO modellerinin tarımsal uygulamaları ve gelişimleri, bu hastalıkların teşhisindeki yenilikçi yaklaşımlar olarak öne çıkmaktadır. Gelişen teknolojilerin tarım sektörüne entegrasyonunun önemi, verimlilik ve sürdürülebilirlik açısından kritik olduğu vurgulanmakta, yapay zekanın tarımsal hastalıkların tespiti ve yönetiminde nasıl devrim yaratabileceği üzerinde durulmaktadır.

"Materyal ve Yöntem" bölümünde, tezin araştırma süreci ve kullanılan metodoloji detaylandırılmıştır. Buğday ve mısır yaprak hastalıklarının tespiti için derin öğrenme ve görüntü işleme tekniklerinin uygulanışı ayrıntılı bir şekilde ele alınmıştır. Bu çalışmada, buğday ve mısır için ayrı ayrı veri setleri hazırlanmış, ResNet ve YOLO model aileleri kullanılarak hastalıkların tespiti gerçekleştirilmiştir. ResNet modelleri mısır için, YOLO modelleri ise buğday için tercih edilmiş, her iki durumda da model performanslarının karşılaştırmalı analizleri sunulmuştur. Ayrıca, hastalık tespitinde kullanılan görüntü işleme teknikleri, model eğitimi süreçleri ve hiperparametre ayarları gibi teknik detaylar da bu bölümde ayrıntılı olarak açıklanmıştır.

"Bulgular" bölümünde, derin öğrenme ve görüntü işleme teknikleri kullanılarak mısır ve buğday bitkilerindeki yaprak hastalıklarının tespiti üzerine yapılan kapsamlı bir çalışma sunulmaktadır. Mısır yaprakları için Residual Network (ResNet) modelleri, buğday yaprakları için ise You Only Look Once (YOLO) modelleri kullanılmıştır. Bu modellerin performansları, farklı ölçütler altında değerlendirilerek, mısır için ResNet101 ve buğday için YOLOv8 modelinin benzer veri setlerine kıyasla daha üstün sonuçlar verdiği

gözlemlenmiştir. Bu bölümde yapay zeka tabanlı yaklaşımların tarımsal hastalık tespitindeki etkinliği ve potansiyeli de açıklamıştır.

"Sonuç ve Tartışma" bölümünde, küresel ölçekte artan endüstriyel faaliyetler, iklim değişiklikleri ve şehir merkezlerine göç gibi faktörlerin tarımsal arazi kullanımının etkinliğini artırmanın zorunluluğunu ortaya koyduğu belirtilmiştir. Tarım alanlarının verimli kullanımı ve bitki hastalıklarının yönetimi için yapay zeka ve teknolojinin kritik bir role sahip olduğu vurgulanmıştır. Bu çalışmada, mısır yaprak hastalıklarının sınıflandırılması amacıyla derin öğrenme tabanlı ResNet modeli kullanılmış ve bu modelin çeşitli versiyonları test edilmiştir. ResNet-101 modelinin %94,56 başarı oranıyla en etkili model olduğu tespit edilmiştir. Ayrıca, buğday yaprak hastalıklarının tespiti için YOLO modellerinin kullanıldığı başka bir uygulama yapılmıştır, YOLOv8 modelinin YOLOv5s modeline göre üstün bir performans sergilediği gözlemlenmiştir. YOLOv8 modelinin başarısında, veri artırma tekniklerinin önemli bir rol oynadığı belirtilmiştir. Sonuç olarak, yapay zeka tabanlı tarım uygulamalarının, bitki hastalıklarının tespiti ve sınıflandırılmasında önemli bir yere sahip olduğu ve bu teknolojilerin tarımsal üretimin verimliliğini artırma potansiyeline sahip olduğu vurgulanmaktadır. Yapay zekanın tarımdaki kullanımının genişlemesi, hastalıklı bitki yapraklarının erken tespiti ve analizi ile tarımsal üretimin verimliliğini artırabilir ve bu gelişmeler, teknoloji tabanlı tarımın ilerlemesine katkıda bulunarak çiftçilere maliyet düşürme ve verimlilik artışı sağlayabilir.

Tezin son bölümü olan "Öneriler" başlığında, ResNet ve YOLO gibi gelişmiş derin öğrenme modellerinin tarımsal uygulamadaki etkinliği üzerine yapılan bu araştırmanın sonuçları temelinde, gelecekteki çalışmalar için çeşitli öneriler sunulmuştur. Bu öneriler arasında, derin öğrenme alanındaki farklı modellerin tarımsal hastalık tespitinde kullanılması ve bu modellerin optimizasyonu yer almaktadır. GAN ve LSTM gibi alternatif algoritmaların kullanımı, hastalık tespitindeki başarı oranını artırabilir. Ayrıca, mısır ve buğday dışında diğer bitki türleri için de özelleştirilmiş veri setlerinin geliştirilmesi, modelin genelleştirme kabiliyetini artırarak daha geniş bir bitki yelpazesinde etkin olmasını sağlayabilir. Bu çalışmada ayrıca, zirai ilaçlama dronları ve uzaktan algılama teknolojilerinin entegrasyonunun, hastalıkların erken evrelerde tespiti ve hızlı müdahale stratejileri geliştirmede önemli bir rol oynayabileceği belirtilmiştir. Uzman sistemler ve akıllı tarım uygulamalarının kullanımı, tarımın sürdürülebilirliğini

artırabilir ve çevre üzerindeki olumsuz etkileri azaltabilir. Son olarak, farklı tarım ürünleri üzerinde yapılan çalışmalar, çeşitli modellerin etkinliğinin karşılaştırmalı analizi ve model uyarlaması için zengin bir veri kaynağı sunmaktadır. Bu öneriler, derin öğrenme ve yapay zeka teknolojilerinin tarımsal uygulamalardaki gelecekteki yönünü belirleyecek ve bu alandaki araştırmalara yeni perspektifler kazandırılacağı üzerine odaklanmaktadır.



2. KAYNAK ÖZETLERİ

Mısır ve buğday, besin açısından zengin kaynaklar olarak endüstriyel üretim ve hayvan yemi olarak önemli rol oynamaktadır. Mısır, insan ve hayvan beslenmesindeki temel rolünün yanı sıra, biyoetanol ve nişasta bazlı şeker gibi çeşitli sanayi ürünlerinin üretiminde de kritik bir hammaddedir. Buğday ise, dünya genelinde temel gıda mahsullerinden biri olarak kabul edilmektedir. Mısır ve buğday çeşitli yaprak hastalıkları nedeniyle tehdit altında bulunmaktadır. Bu hastalıklar, bitkilerde lekelenme, sararma ve verim kaybı gibi belirtilerle kendini gösterir mısır ve buğday üretiminde ciddi kayıplara yol açabilir. Bu nedenle, mısır ve buğday hastalıklarının erken teşhisi ve etkili mücadele yöntemleri, tarımsal üretimde sürdürülebilirlik ve gıda güvenliği için büyük önem taşımaktadır.

Dünya nüfusunun artmasıyla birlikte tarımsal üretim giderek daha önemli hale gelmiştir. MÖ 7000'den 1830'a kadar dünya nüfusu 10 milyondan 1 milyara yükselmiştir (Cramer, 1967; Özer vd., 2003). 19. yüzyılın başlarında dünya nüfusu 1 milyar iken, 20. yüzyılın başlarında 2 milyara, 21. yüzyılın başlarında ise 6,5 milyara ulaşmıştır (TMO, 2009; Acıbuca, 2010). Bu artış, gıda maddesi ihtiyacını da artırmaktadır. Cramer (1967) tarafından yapılan bir çalışmada, bitki koruma etmenlerinden dolayı buğday, arpa, yulaf ve çavdar bitkisinde yaklaşık olarak %22,9' luk ürün kaybı olduğu bildirilmiştir.

Bitkisel üretimde bitkinin hastalıkları ile mücadele, ülkemizin gıda güvenliği açısından büyük önem taşımaktadır. Özellikle bitki yapraklarındaki hastalıklar ve zararlılar, üretim aşamasında %30 ile %35 oranında zarara yol açabilmekte, salgın durumlarında bu oran %100'e kadar çıkabilmektedir (Bayer Tarım Crop Science Türkiye, 2022).

Mısır ve buğday, dünya genelinde temel gıda kaynakları arasında yer almakta ve geniş çapta tarımı yapılan önemli tahıl ürünleridir. Bu tahılların verimliliği, birçok faktöre bağlı olmakla birlikte, yaprak hastalıklarının erken tespiti ve kontrolü bu faktörlerin başında gelir. Yaprak hastalıkları, hem mısır hem de buğdayda görülebilen, verimi ve kaliteyi önemli ölçüde düşürebilen sorunlardır. Bu hastalıkların zamanında tespit edilip müdahale edilmesi, tarımsal üretimde beklenen verimin elde edilmesi ve gıda güvenliğinin sağlanması açısından kritik öneme sahiptir.

Geleneksel hastalık tespit yöntemleri genellikle zaman alıcıdır ve uzman bilgisi gerektirmektedir. Bu durum, özellikle geniş tarım alanlarında etkin bir şekilde hastalık yönetimi yapılmasını zorlaştırmaktadır. Bu nedenle, son yıllarda, yapay zeka ve makine öğrenmesi tekniklerinin tarımda kullanımı artmıştır. Özellikle görüntü işleme ve derin öğrenme tabanlı modeller, mısır ve buğday yaprak hastalıklarının hızlı ve doğru bir şekilde tespit edilmesinde önemli bir rol oynamaktadır. Bu teknolojiler, bitki yapraklarından alınan görüntüler üzerinden hastalık belirtilerini otomatik olarak sınıflandırabilmekte ve tarım sektöründe hastalık yönetimini kolaylaştırmaktadır.

Mısır ve buğday yaprak hastalıkları üzerine yapılacak olan kapsamlı bir kaynak taraması, bu alandaki mevcut bilgi birikimini derlemek ve araştırma için bir temel oluşturmak amacıyla kritik öneme sahiptir. Bu bağlamda, derinlemesine bir literatür taraması yapmak, hastalık tespit yöntemlerindeki mevcut teknolojileri, yöntemleri ve araştırma yönelimlerini belirlemek için temel bir adımdır. Görüntü işleme ve derin öğrenme gibi modern teknolojilerin tarımda kullanımı, son yıllarda dikkat çekici ilerlemeler kaydetmiştir. Bu tekniklerin uygulanabilirliği, etkinliği ve potansiyel sınırlılıkları, literatürde detaylı bir şekilde incelenmiştir.

Yapılacak olan kaynak taraması, aynı zamanda, bu alandaki boşlukları ve gelecek araştırmalar için potansiyel fırsatları da ortaya koyacaktır. Bu, araştırma ve geliştirme çalışmalarının yönlendirilmesine yardımcı olacak ve mısır ve buğday üretiminde karşılaşılan zorluklara yenilikçi çözümler sunma potansiyelini artıracaktır. Bu nedenle, kaynak taraması aşaması, bilgi birikiminin yanı sıra araştırma yönelimini de şekillendirecek önemli bir süreçtir.

2.1. Mısır Konusunda Yapılan Çalışmalar

Mısır, insan gıdası ve hayvan yemi olarak kullanılmasıyla beraber, biyoetanol, alkol, ispirto, şurup, yağ, tutkal, irmik ve nişasta temelli şeker gibi sanayi ürünlerinin üretiminde de hammadde olarak önemli bir rol oynamaktadır (Akarken ve Taş, 2014; Tarım ve Orman Bakanlığı, 2014).

Tarım kaynaklarını daha verimli kullanmak ve bitki hastalıklarını doğru tespit etmek amacıyla derin öğrenme teknolojileri üzerinde çeşitli çalışmalar yapılmaktadır. Bu

alışmalar, mısır yapraklarında grlen hastalıkların tespiti zerine odaklanmakta ve srdrlebilir tarımda mısır retiminde verimlilięi dřren hastalıkların belirlenmesi nem tařıamaktadır. Sibiya ve Sumbwanyambe (2019), mısır yaprak hastalıklarının tespiti iin evriřimli sinir aęları ve Neuroph kullanmıřlardır.

Zeng vd. (2020) tarafından yapılan alıřma, Huanglongbing (HLB) - (turungil yeřilimsi sarılık hastalıęı) tarafından enfekte edilmiř narenciye yapraklarının sınıflandırılmasına yneliktir. Inception_v3 modeli kullanılan bu arařtırma, GAN tabanlı veri artırmayla %92,60 doęruluk oranı elde etmiřtir.

Trkoęlu vd. (2020), kayısı hastalıklarının tespiti iin Derin Evriřimsel Sinir Aęları modelini kullanmıřtır. Sun vd. (2020), tarafından yapılan arařtırma, kuzey mısır yaprak yanıklılıęının tespiti iin derin ęrenme tabanlı bir yntem nermiřtir. Geliřtirilmiř model, %91,83 ortalama doęruluk oranında bařarı gstermiřtir.

Gksu vd. (2021), derin ęrenme yntemleriyle mısır yapraklarındaki hastalıkları tespit etmek iin EfficientNetB5 ve Evriřimsel Sinir Aęları (CNN) tabanlı iki model geliřtirmiř, EfficientNetB5 modeli %92,12 CNN modeli ise %89,88 tahmin bařarısı gstermiřtir.

Hassan vd. (2021), mısır, patates ve domates gibi farklı bitkilerde hastalık tespiti iin Rastgele Orman (RF) ve Grsel Geometri Grubu (VGG) ile Ekstrem Gradyan Artırma (Xgboost) yntemlerini kullanmıřlardır. Bu alıřmada, mısır yapraklarındaki hastalıklar %94,47, patates hastalıkları %98,74 ve domates hastalıkları %93,91 doęruluk oranıyla tespit edilmiřtir. Tuncer (2021), tarafından yapılan alıřma, bitki yaprak hastalıklarının tespiti iin CNN modellerini incelemiřtir. Yeni bir hibrit CNN yaklařımı neren bu alıřma, parametre sayısını azaltarak hafif modeller elde etmeyi amalamıřtır. nerilen model %99,27'ye varan doęruluk oranında sonular gstermiřtir.

Khattak vd. (2021), tarafından yapılan arařtırma, narenciye meyve verimini dřren hastalıkların tespiti iin derin ęrenme metodlarını kullanmıřtır. nerilen CNN modeli %94,55 test doęruluęuna ulařarak, narenciye meyve/yaprak hastalıklarını sınıflandırmak iin etkili bir ara olarak ortaya ıkmıřtır. Aslan (2021), řeftali aęacı hastalıklarının tespitinde AlexNet modelini kullanarak monilya ve kořnili hastalıklarını belirlemiřtir.

Sunil vd. (2021) tarafından yapılan araştırma, Hindistan'da yetişen kakulenin hastalık tespitine odaklanmıştır. U2-Net ve EfficientNetV2 modelleri kullanılarak yapılan bu çalışmada, %98,26 tespit doğruluğu elde etmiştir.

Çetiner (2021), mısır bitkisi dışında, elma ağacı yapraklarındaki hastalıkları tespit etmek için MobileNetV2, DenseNet201, ResNet50V2, ResNet101V2 ve ResNet152V2 algoritmalarını kullanmıştır.

Kartikeyan ve Shrivastava (2022), bitki hastalıklarının tespiti için kullanılan çeşitli derin öğrenme modellerini karşılaştırmış ve en yüksek başarıyı DenseNet (%99,75) ve GoogLeNet (%98,78) ile bulmuşlardır.

Paymode ve Malode (2022), üzüm ve domates yapraklarındaki hastalıkları tespit etmek için Evrişimsel Sinir Ağları (CNN) ve CNN tabanlı VGG modelini kullanmışlar ve domates için %95,71, üzüm için %98,40 doğrulukta sonuçlar elde etmişlerdir.

Palanisamy ve Sanjana (2022), araştırma çalışması mısırın hastalıklı yaprakların tanımlanması ve tespit edilmesinde çeşitli metodolojileri analiz etmekte ve hastalık tespiti için çeşitli sınıflandırıcıları araştırmaktadır. Son beş yılın araştırma literatürü, yalnızca temel yaklaşımlar dahil edilerek kapsamlı bir şekilde incelenmiştir. Bu nedenle, çalışma spesifik bir model üzerinde yoğunlaşmaktan ziyade, genel bir literatür taraması sunmaktadır.

Amin vd. (2022), tarafından gerçekleştirilen çalışmada, bitki hastalıklarının tanımlanmasında derin öğrenme tekniklerinin etkinliği incelenmiştir. Geleneksel yöntemlere alternatif olarak önerilen model, sağlıklı ve sağlıklı mısır yapraklarını ayırt etmek için EfficientNetB0 ve DenseNet121 gibi iki evrişimli sinir ağını kullanmıştır. Model, derin özellikler çıkarmak ve bu özellikleri birleştirerek karmaşık bir özellik seti oluşturmak amacıyla geliştirilmiştir. Ayrıca, modelin veri setine çeşitlilik katmak için veri artırma teknikleri kullanılmıştır. Sonuçlar, önerilen modelin %98,56 sınıflandırma doğruluğuna ulaştığını ve diğer CNN modellerinden üstün olduğunu göstermiştir.

Saleem vd. (2022) tarafından yapılan çalışma, derin öğrenme tabanlı bitki hastalığı tespiti için yenilikçi bir yaklaşımı sunmaktadır. Bu araştırma, Yeni Zelanda'nın beş ana bahçe ürününe odaklanan NZDLPlantDisease-v1 veri setini tanıtmış ve bitki organlarında

birden fazla hastalığın tespitine yönelik olmuştur. Optimize edilmiş bir derin öğrenme modeli olan Bölge Tabanlı Tam Evrişimli Ağ (RFCN) kullanılmış ve modelin doğruluk oranı %93,80 olarak bulunmuştur.

Ahmed vd. (2022) tarafından yapılan araştırma, domates yaprak hastalıklarının tespiti için hafif bir derin öğrenme tabanlı yaklaşımı önermiştir. Önerilen model %99,30 doğruluk oranı ile etkili sonuçlar göstermiştir.

Chen vd. (2022) tarafından yapılan çalışmada, derin öğrenmenin bitki hastalıklarının tanıma ve tespitindeki kullanımı incelenmiştir. Mobile-Net adı verilen hafif bir ağ mimarisi öneren bu çalışma %99,21 ortalama tanıma doğruluğu ile dikkat çekmiştir.

Mısır yapraklarındaki hastalıkların tespitinde yapay zeka kullanımını ele alan Akar vd. (2022) çalışması, Residual Network (ResNet) modellerinin etkinliğini vurgulamaktadır. İklim değişikliklerinin etkisi altında sürdürülebilir tarımın önemi artarken, bu çalışma, ResNet modelleri kullanarak mısır yapraklarındaki hastalıkları sınıflandırmaktadır. Özellikle, ResNet101 modeli, diğer modellerle kıyaslandığında daha yüksek bir başarı oranı sergilemiş, bu da yapay zekanın tarım alanındaki uygulamalarındaki potansiyelini göstermektedir.

Cıran ve Özbay (2022) tarafından yapılan araştırma, mısır yapraklarındaki yanık, pas ve gri yaprak lekesi gibi hastalıkların erken teşhisi ve tedavisi için yenilikçi bir yaklaşım sunmuştur. Araştırmada, CNN tabanlı VGG-19, DenseNet-201 ve NasNet-Large gibi çeşitli modeller kullanılarak mısır yapraklarından özellik çıkarımı yapılmıştır. Veri setindeki dengesizlik, Sentetik Azınlık Yüksek Örnekleme Tekniği (SMOTE) ile giderilmiş, boyut indirgemesi için Temel Bileşen Analizi (PCA) kullanılmıştır. Hastalıkların sınıflandırılmasında Destek Vektör Makineleri (SVM) algoritması tercih edilmiş ve GridSearchCV ile hiperparametre optimizasyonu yapılmıştır. Kaggle veri seti üzerinde yapılan testlerde, CNN ile elde edilen özelliklerin LibSVM ile sınıflandırılması sonucunda sırasıyla %94,5, %94,4, %94,3 ve %96,2 gibi yüksek doğruluk oranları elde edilmiştir. Önerilen yöntemle LibSVM kullanılarak %96,7 doğruluk oranı ve ağırlıklı olarak %96,7 ortalama doğruluk sağlanmıştır, bu da önceki sonuçlara göre önemli bir iyileşme olduğunu göstermektedir.

Bi vd. (2023) çalışmalarında, mısır yaprak hastalıklarının tespiti için geliştirilmiş bir Mobilenetv3 modeli (CD-Mobilenetv3 - Geliştirilmiş Mobilenetv3 Modeli) üzerinde odaklanmışlardır. Bu çalışmada, modelin doğruluğunu artırmak için çeşitli yenilikler yapılmıştır, örneğin önyargı kayıp fonksiyonunun kullanılması ve ECA (Efficient Channel Attention - Verimli Kanal Dikkati) modülünün eklenmesi ile CD-Mobilenetv3, hibrit açık kaynaklı bir veri seti olan CLDD (Corn Leaf Disease Dataset - Mısır Yaprak Hastalığı Veri Seti) üzerinde %98,23 doğruluk elde edilmiş ve klasik derin öğrenme modellerine göre daha üstün performans sergilendiği belirtilmiştir.

Rajeena PP vd. (2023) sundukları çalışmalarında, yanlış pestisit kullanımını önleyerek ve tarımsal verimliliği artırarak, mısır hastalıklarını doğru ve otomatik bir şekilde tespit etmeyi amaçlamaktadırlar. Çalışma, görüntü alımı, ön işleme (preprocessing) ve sınıflandırma (classification) işlemlerini kapsamaktadır. Ön işlemede, görüntülerin okunması, boyutlandırılması ve veri artırılması gibi adımlar yer alırken, EfficientNet mimarisi ile mısır yaprak hastalıkları veritabanının doğruluğu artırılmıştır. Yapılan testler, bu yaklaşımın %98,85 tanıma doğruluğu ile diğer ileri tekniklere kıyasla üstün olduğunu göstermektedir.

Rashid vd. (2024) tarafından IEEE Access dergisinde yayımlanan makalede, mısır bitkisi yaprak hastalıklarının erken ve akıllıca tespiti için IoT (Internet of Things - Nesnelerin İnterneti) ve derin öğrenme çoklu modellerinin kullanıldığı açıklanmıştır. Çalışmada, Arduino ile Multi-Model Fusion Network (MMF-Net - Çoklu Model Birleşim Ağı) adında bir yapay zekâ modeli geliştirilmiştir. MMF-Net, farklı veri türlerini işleyerek mısır yaprak hastalıklarını yüksek doğrulukla (%99,23) sınıflandırabilen üç ana bileşenden oluşmuştur: RL-Block (Spatial Range Block - Mekânsal Aralık Bloğu), PL-Block 1 (Perceptual Learning Block 1 - Algısal Öğrenme Bloğu 1) ve PL-Block 2 (Perceptual Learning Block 2 - Algısal Öğrenme Bloğu 2).

Palanisamy ve Sanjana (2023), çalışmalarında, mısır yaprak enfeksiyonunun erken tespiti için bir sistem tasarlamış ve Deep Learning algoritmalarını kullanmışlardır. Kullanılan modeller arasında Sequential 2-Dimensional model ve Dense Net model bulunmaktadır. Ayrıca, Ensemble Learning tekniklerinden Ağırlıklı Oylama (Weighted Voting) kullanılarak %98 doğruluk elde edilmiştir.

Brenya vd. (2024) tarafından yapılan çalışmada, mısır yapraklarında tüm büyüme aşamalarında hastalıkların tespiti için bir CNN modelinin geliştirilmesine odaklanılmıştır. Araştırma, Pythium Chloric hastalığı, Rhizoctonia tohum çürüklüğü ve Penicillium yaprak kurutma hastalığı gibi mısır bitkilerini tüm büyüme aşamalarında etkileyebilecek en yaygın hastalık türlerine yöneliktir. Geliştirilen model, Flask web uygulaması aracılığıyla çiftçilere sunulmuş ve %94,76 test doğruluğu ile mısır bitkilerindeki hastalıkları yüksek doğrulukla tespit ettiği belirlenmiştir. Modelin çiftçilere ve tarım sektörüne sunulması, mısır verimindeki olumsuz etkileri azaltmada önemli bir adım olarak değerlendirilmektedir.

2.2. Buğday Konusunda Yapılan Çalışmalar

Genel olarak, buğday yaprak hastalıkları buğday üretimini tehdit eden önemli bir sorun olup, etkili mücadele yöntemlerinin geliştirilmesi gerekmektedir. Buğday yaprak hastalıklarının erken teşhisi ve etkili bir şekilde kontrol edilmesi için, veri setleri kullanılarak geliştirilen makine öğrenimi modelleri önemli bir rol oynamaktadır.

Aktaş ve Arslan (2017) tarafından belirtildiği üzere, buğday yaprak hastalıklarının etkenleri çoğunlukla mantarlar olmakla birlikte, bakteriler, virüsler ve nematodlar da hastalıklara neden olabilmektedir. Bu hastalıkların belirtileri etkene göre değişiklik gösterse de genellikle yapraklarda lekeler, çürümeler, sararmalar ve kıvrılmalar şeklinde kendini göstermektedir.

Başaran ve Kılıç (2019) buğday yaprak hastalıklarının rüzgâr, su ve böcekler aracılığıyla yayılabileceğini vurgulamaktadır. Hastalığın yayılmasını önlemek için ekim nöbeti, hastalıktan arı tohum kullanımı ve hastalık belirtileri görülen bitkilerin imhası gibi önlemlerin alınabileceği belirtilmiştir.

Türkoğlu (2019) tarafından gerçekleştirilen çalışmada, bitki yaprağının geometrik özelliklerine dayanan ve yaprak tabanlı sınıflandırmalar için hibrit sistemler gibi yenilikçi yöntemler geliştirilmiştir. Derin öğrenme ve evrimsel sinir ağları tabanlı modeller, bitki türlerinin tanımlanmasında ve hastalıklarının tespitinde etkili bulunmuştur. Yapılan deneysel çalışmalar, bu yöntemlerin yüksek doğruluk oranları ile bitki hastalıklarını

başarıyla tanıyabildiğini göstermiştir. Geliştirilen sistemler, tarımsal alanlarda otomatik tanı ve tespit sistemlerine temel oluşturarak, bu alanda önemli bir adım atılmıştır.

Akan (2019) tarafından yürütülen çalışmada, makarnalık buğday hatlarının sarı pas hastalığına karşı dayanıklılığı araştırılmıştır. Çalışma, 2006'dan 2016'ya kadar süren ve farklı ıslah programlarından elde edilen 61 makarnalık buğday hattının sera ve tarla koşullarında test edilmesini içermektedir. Hastalık değerlendirmeleri Modifiye Cobb skalasına göre yapılmış, GGE-biplot analiziyle dayanıklı genotipler etkin şekilde belirlenmiştir. Bu araştırma, sarı pas hastalığına dayanıklı buğday hatlarının geliştirilmesi için önemli bir katkı sunmuştur.

Aksoy vd. (2020) tarafından yürütülen araştırmada, elma bitkisindeki uyuz, siyah çürük ve pas hastalıklarının tespiti için çeşitli CNN mimarileri kullanılmıştır. Çalışmada, AlexNet, DenseNet-121, SqueezeNet1_0, VGG16-BN ve ResNet-34 gibi mimarilerin performansları değerlendirilmiş ve ResNet-34 modelinin duyarlılık, özgüllük, doğruluk ve F-skor açısından yüksek sonuçları verdiği tespit edilmiştir. Test veri seti için bu model, sırasıyla %97,64, %99,54, %99,52, %98,62 değerlerine ulaşarak başarılı bir performan göstermiştir.

Kızılboğa (2021) tarafından yapılan araştırmada, çeşitli hastalıkların etkilediği elma ve ayva bitkilerinin görüntüleri üzerinde yapay sinir ağları ve derin öğrenme teknikleri kullanılarak analizler yapılmıştır. Toplamda 12.600 görüntü içeren genişletilmiş bir veri seti üzerinde, evrişimli derin ağlar ve aktarımlı öğrenme yöntemleri ile hastalıkların sınıflandırılması gerçekleştirilmiştir. Geliştirilen model, SVM ve K-NN gibi geleneksel yöntemlerle kombine edilerek test edilmiş ve yüksek doğruluk oranlarına ulaşılmıştır. Bu çalışma, elma ve ayva hastalıklarının gerçek zamanlı tespitine yönelik önemli bir katkı sağlamaktadır.

Getachew ve Hawi (2021), çalışmalarında, buğday hastalıklarının tespiti alanında karşılaşılan zorlukları ele almaktadır. Geleneksel gözlem yöntemleriyle hastalık tespiti zor olabileceği durumlarda, laboratuvar materyalleri olmadan kesin bir tanı koymak güçleşebilmektedir. Yapılan çalışmada yürütülen metodoloji, üç ana aşamadan oluşmaktadır: veri toplama, en iyi hiperparametrelerin belirlenmesi ve test aşaması. VGG19, InceptionV3, MobileNet ve EfficientNet gibi önceden eğitilmiş modeller

kullanılmış, MobileNet modeli diğerlerine göre en iyi sonucu elde etmiş ve %90 doğruluk oranı ile başarılı bir sınıflandırma gerçekleştirmiştir.

Eğerçi vd. (2021) tarafından yapılan çalışmada, buğday yaprak hastalıklarının verim kaybına, kalite düşüşüne ve hatta ürün kaybına yol açabileceği belirtilmiştir. Hastalığın neden olduğu zararın miktarı, hastalığın şiddeti, hava koşulları ve bitki koruma önlemlerine bağlı olarak değişebilir. Buğday yaprak hastalıklarıyla mücadelede uygulanan üç temel yöntemi; kimyasal mücadele, biyolojik mücadele ve kültürel önlemleri belirtmişlerdir. Kimyasal mücadelenin en yaygın yöntem olduğu, ancak çevre ve insan sağlığına olumsuz etkileri olduğu vurgulanmıştır. Çalışmaya göre, Ege Bölgesi'nde yaygın olarak görülen Septorya yaprak lekesi hastalığına karşı, bölgede yaygın olarak yetiştirilen buğday çeşitlerinin çoğu hassastır. Sadece Alatay çeşidi orta dayanıklı olarak belirlenmiştir ve bu çeşidin hastalığın her yıl görüldüğü alanlarda ekimi önerilmektedir.

Hayit (2021) tarafından yapılan araştırmada, Sarı Pas (*Puccinia striiformis*) hastalığı, özellikle Orta Anadolu'da buğday verimini ve kalitesini olumsuz etkileyen önemli bir faktör olarak belirlenmiştir. Bu hastalığın tespiti için tarla ortamından alınan buğday yaprak görüntülerinin doku analizi ve derin öğrenme tekniklerinin kombinasyonu kullanılarak sınıflandırılması incelenmiştir. Geliştirilen hibrit yöntem, geleneksel metotlar ve derin öğrenme tabanlı modellerden elde edilen öznetelikleri birleştirerek yüksek doğruluk oranına ulaşmıştır.

Bitkilerde hastalıkların erken aşamada teşhis edilmesi tarımsal ürünlerin korunması için hayati önem taşımaktadır. Yaklaşık 500 görüntüye dayalı çalışmada, VGG-CNN eğitimi ile Destek Vektör Makineleri (SVM) ve ResNet mimarileri karşılaştırılmıştır. ResNet modeli daha fazla özelliği sınıflandırabilen ve en iyi doğruluk sağlayan model olarak belirlenmiştir (Srilakshmi vd., 2021).

Çat (2022) tarafından yapılan çalışmada, Türkiye'de tescilli 54 makarnalık buğday çeşidinin sarı pasa karşı dayanıklılığı değerlendirilmiştir. Bu çalışmada, çeşitlerin mevcut hastalık popülasyonuna karşı test edilmesi ve tarla koşullarında dayanıklılık gösteren çeşitlerin belirlenmesi gerçekleştirilmiştir.

Çiçek vd. (2022) tarafından yapılan bir araştırmada, şeker pancarı üretiminde yapay zekâ kullanımının, verim ve kalitenin artırılması, maliyetlerin düşürülmesi ve çevresel etkilerin azaltılması gibi birçok faydası olduğu belirtilmiştir.

Biçgi ve Karaca (2022) tarafından yapılan çalışmada, YOLOv4 nesne tespit algoritması kullanılarak patates böceğinin ergin ve son dönem larvalarının patates bitkisi üzerinde tespiti araştırılmıştır. Önerilen model, giriş görüntü çözünürlüğünün 1024 x 1024 olduğu durumda en uygun sonuçları elde etmiştir ve YOLOv4 algoritması, patates böceğinin ergin ve son dönem larvalarını yüksek başarıyla tespit edebileceği gösterilmiştir.

Xu vd. (2023) yaptığı çalışmada, buğday yaprak hastalıklarının tanımlanmasında derin öğrenme algoritmalarını kullanılmıştır. Bu araştırmada, RFE-CNN adlı entegre bir derin öğrenme algoritması önerilmiş ve bu algoritma, residual channel attention block (RCAB), feedback block (FB), elliptic metric learning (EML) ve convolutional neural network (CNN) unsurlarını birleştirmektedir. RFE-CNN modeli, GoogLeNet, VGG-19, ZFNet, Inception-V4 ve Efficient-B7 gibi diğer modellere göre daha yüksek tanıma doğruluğu ve zaman verimliliği sağlamıştır. Araştırma, %98,83 genel sınıflandırma doğruluğu ve %99,95 maksimum test doğruluğu ile dikkat çekmektedir.

Neog vd. (2023) inceleme makalesinde, buğday yaprak hastalıklarını tespit etmek ve sınıflandırmak için çeşitli makine öğrenimi tekniklerini tartışmaktadır. Çiftçilere büyük plantasyon alanlarını izlemeye yardımcı olan bu teknolojilerin önemini vurgulamakta ve buğday yaprak hastalığı tespitindeki ana sorun ve zorlukları öne çıkarmaktadır.

Jouini vd. (2023) araştırmalarında, hastalık sınıflandırmasının hızını ve doğruluğunu artırmak için CNN tabanlı bir buğday yaprak hastalığı tespit ve sınıflandırma yöntemi önermektedir. Çalışma, çeşitli görüntü artırma yaklaşımlarını kullanarak aşırı uyum sorununu ele almakta ve %94 test doğruluğu elde etmektedir. Bu yöntem, kaynak kısıtlı ortamlarda gerçek zamanlı buğday hastalığı tespiti için yöntemin uygulanabilirliğini de göstermektedir.

Gao vd. (2023) yürüttüğü çalışma, buğday çizgili pasının şiddetini belirleme konusunda yenilikçi bir çözüm sunmaktadır. Araştırma, geleneksel yöntemlerin küçük örneklem boyutları ve lezyonların düzensiz şekilleri nedeniyle yaşanan doğruluk eksikliğini

gidermeyi hedeflemektedir. Bu sorunu çözmek için SLIC süperpiksel segmentasyonu ve RF rastgele orman algoritması birleştirilmiştir. Bu yöntem, lezyonları alt bölgelere ayırarak ve bu alt bölgeleri sınıflandırarak doğru lezyon çıkarma sağlamaktadır. Lezyon alan yüzdesi, alt bölge görüntülerinin birleştirilmesi ve piksel analizi ile hesaplanarak, pasın şiddetinin belirlenmesini mümkün kılmaktadır. Araştırma sonuçları, bu yöntemin lezyon çıkarma doğruluğunda su bölmesi segmentasyonu ve K-Ortalamalar kümelemesinden daha üstün olduğunu göstermektedir. Bu yaklaşım, buğday çizgili pası lezyonlarının ve solan yeşil alanların daha doğru şekilde tespit edilmesini sağlayarak, pasın önlenmesi ve kontrolü için önemli katkılar sunmaktadır.

Aydoğdu ve Akan (2023) tarafından gerçekleştirilen çalışmada, makarnalık ve ekmeklik buğday çeşitlerinin farklı fenolojik dönemlerde sarı pasa karşı verdiği tepkiler incelenmiştir. Bu çalışmada, çeşitli buğday türlerinin yapay epidemik şartlarında hastalık şiddetlerinin değişimi ve hastalığa verilen reaksiyonlar incelenmiştir. Elde edilen sonuçlar, özellikle bağışıklık sistemini zayıflatan dönemlerde hastalık şiddetindeki artışların istatistiksel olarak önemli olduğuna dair bulgular elde edilmiştir. Bu çalışmalar, sarı pas hastalığının kontrolü ve buğday ıslahı üzerinde önemli bilgiler sağlamaktadır.

Zhang vd. (2023) tarafından yapılan çalışmada, buğdaydaki Fusarium Baş Çürüklüğü (FHB) hastalığının tespiti için geliştirilen iki yeni yöntem incelenmiştir. Araştırmada Dönembilen Yolo Buğday Tespit (RYWD) ağı ve Basit Mekansal Dikkat (SSA) ağı tanıtılmış ve bu yöntemlerle FHB'nin tespitinde %94,66'lık ortalama doğruluk elde edilmiştir. Çalışma, buğday başı görüntülerinin her yönde tespit edilebilmesini sağlayan RYWD ağının ve mekansal dağılıma dayalı buğday özelliklerini çıkaran SSA ağının tarım hastalıklarının tespitinde önemli iyileştirmeler sağladığını göstermektedir.

Adem vd. (2024) gerçekleştirdikleri "Buğdayda Sarı Pas Hastalığının Tespitinde Derin Öğrenme Modelleri Kullanılarak Evrişim Katmanı Sayısı ve Aktivasyon Fonksiyonlarının Rolünün İncelenmesi" başlıklı çalışması, derin öğrenme tekniklerinin buğdayda sarı pas hastalığını tespit etme ve sınıflandırma kapasitesine katkıda bulunan temel unsurları mercek altına almaktadır. Araştırma, özellikle evrişimli sinir ağları (CNN) kullanılarak, farklı katman sayıları ve aktivasyon fonksiyonlarının sınıflandırma başarımı üzerindeki etkilerini kapsamlı bir şekilde ele alır. Analiz sonuçları, SELU aktivasyon fonksiyonu kullanılarak oluşturulan beş katmanlı bir CNN modelinin, %95,33

sınıflandırma doğruluğu sağladığını göstermektedir. Bu bulgular, derin öğrenme modellerinin parametre seçimindeki hassasiyetin, hastalık tespitindeki başarı oranını önemli ölçüde etkileyebileceğini ortaya koymaktadır.

Chang vd. (2024) tarafından yayınlanan çalışma, geliştirilmiş DenseNet tabanlı bir yöntemle tarla ortamında buğday paslarının tanınmasına odaklanmaktadır. Çalışma, derin öğrenme tekniklerini kullanarak buğdaydaki çizgili, yaprak ve sap pası türlerini ayırt etmeyi hedeflemekte ve bu amaçla çeşitli veri setlerinden toplanan görüntüler üzerinden CNN modelini değerlendirmiştir. Seçilen DenseNet121 modeli, fenotipik morfoloji ve model yapısı analizi ile birlikte karıştırıcı faktörlerin tartışılması temelinde iyileştirilmiş ve bu model WRD (Wheat Rusts Dataset - Buğday Pasları Veri Seti), WDD (Wheat Common Disease Dataset - Buğday Yaygın Hastalık Veri Seti) ve PDD (Common Poaceae Disease Dataset - Yaygın Poaceae Hastalık Veri Seti) veri setlerinde yüksek doğruluk oranları elde etmiştir. Araştırma, buğday paslarının daha etkin tanınmasına yönelik DL tabanlı stratejilerin potansiyelini ortaya koymakta ve buğday hastalıklarının gelecekteki araştırmaları için yeni perspektifler sunmaktadır.

Yapılan çeşitli araştırmalar, mısır, buğday vb. yaprak hastalıklarının tespiti ve sınıflandırılmasında derin öğrenme ve CNN gibi gelişmiş teknolojilerin etkinliğini ortaya koymaktadır. Bu yöntemler, geleneksel tarım uygulamalarına kıyasla hastalıkların daha hızlı ve doğru bir şekilde tespit edilmesini sağlamakta, böylece tarımsal verimliliği artırmakta ve ürün kayıplarını azaltmaktadır. Yüksek doğruluk oranlarına ulaşan bu teknolojik yaklaşımlar, tarımsal alanda otomatik tanı ve tespit sistemlerine temel oluşturarak hem mısır hem de buğday üretimini tehdit eden hastalıklarla mücadelede önemli bir adım atmaktadır. Sonuç olarak, bu teknolojilerin kullanımı, küresel gıda güvenliğini desteklemek ve tarımsal sürdürülebilirliği artırmak için hayati önem taşımaktadır.

3. KURAMSAL TEMELLER

3.1. Tarımsal Üretim

Tarım, insanlık tarihi boyunca var olan ve toplumların temel ihtiyaçlarını karşılamada merkezi bir rol oynayan bir faaliyettir. Tarımın temel amacı, insan nüfusunun artan beslenme ihtiyaçlarını karşılamaktır. Tarım, genellikle bitki ve hayvan yetiştiriciliğini kapsayan, gıda, yem, lif ve diğer ürünlerin üretimini içerir. Buda toprağın işlenmesi, tohumun ekimi, sulanması, gübrelenmesi ve ürünün toplanması gibi çeşitli süreçleri kapsamaktadır. Tarımsal üretimin temel amacı, sürdürülebilir bir şekilde maksimum verim elde etmektir. Tarımsal üretim, dünya nüfusunun artan beslenme ihtiyaçlarını karşılamak ve ekolojik dengeyi korumak için önemlidir. Tarım, doğal kaynakların sürdürülebilir kullanımı, gıda güvenliği ve ekonomik kalkınma açısından kritik bir sektördür. Pretty vd. (2006) ise, sürdürülebilir tarım uygulamalarının, toprağın verimliliğini korumak, su kaynaklarını etkin bir şekilde yönetmek ve biyolojik çeşitliliği desteklemek için hayati önem taşıdığını belirtmiştir. Tarımsal verimlilik, kaliteli gıda üretimi yapılırken kaynakların etkin kullanımını ifade eder ve bu bağlamda, entegre zararlı yönetimi ve organik tarım gibi uygulamalar dikkate alınmıştır. Foley vd. (2011) tarafından yapılan bir çalışmada, tarımsal uygulamaların verimliliği ve sürdürülebilirliği üzerine vurgu yapılmıştır. Bu çalışma, gıda üretiminin artırılması ve kaynak kullanımının etkinleştirilmesinin yanı sıra, çevresel etkilerin azaltılmasının önemini ortaya koymuştur.

İklim değişikliği de tarım üzerinde doğrudan etkiler yaratmaktadır. Wheeler ve Von Braun (2013), iklim değişikliğinin tarımsal üretim üzerindeki etkilerini ve bu değişikliklere uyum sağlamak için gerekli tarımsal uygulamaları ve dayanıklı bitki çeşitlerinin geliştirilmesinin önemini vurgulamıştır. Sıcaklık artışları, yağış desenlerindeki değişiklikler ve aşırı hava olayları ürün verimliliğini ve kalitesini etkileyebilir.

Teknolojinin tarımdaki rolü de önemlidir. Bronson ve Knezevic (2016), modern teknolojilerin, tarımsal verimliliği artırmada ve sürdürülebilir uygulamaları desteklemede önemli bir rol oynadığını belirtmiştir. Uydu görüntüleme, uzaktan algılama, yapay zeka ve robotik gibi teknolojiler, tarımsal süreçleri optimize etmekte ve verim kayıplarını azaltmaktadır.

Dünya genelinde tarım, çeşitli iklim ve coğrafi koşullara bağlı olarak farklı şekillerde yapılır. Gelişmiş ülkelerde genellikle büyük ölçekli ve mekanize tarım uygulamaları görülürken, gelişmekte olan ülkelere küçük ölçekli, aile işletmeleri şeklindeki tarım yaygındır. Tarım, bu ülkeler için ekonomik kalkınmanın ve gıda güvenliğinin temelini oluşturur. Özellikle Türkiye, Afrika, Asya ve Latin Amerika'daki birçok ülkede tarım, toplam iş gücünün önemli bir bölümünü oluşturur ve milli gelirin büyük bir kısmını sağlar.

Tarımsal üretimde, bitki hastalıkları ve zararlılar önemli bir verim kaybı nedenidir. Funguslar, bakteriler, virüsler ve zararlı böcekler, tarımsal ürünlerde hastalıklara ve zararlılara yol açabilir. Bu hastalık ve zararlıların etkin bir şekilde yönetimi, tarımsal üretimde verimliliği artırmak ve gıda güvenliğini sağlamak için kritik öneme sahiptir.

Türkiye'de tarım, ekonominin ve kültürel yaşamın önemli bir parçasıdır. Türkiye, çeşitli iklim koşulları ve geniş arazi yapısı sayesinde çok çeşitli tarım ürünleri üretir. Buğday, mısır ve arpa gibi tahılların yanı sıra zeytin, çay, tütün, meyve ve sebzeler önemli tarım ürünleridir. Türkiye, ayrıca özellikle Akdeniz ürünleri olan zeytinyağı ve narenciye ürünleriyle de dikkat çeker. Türkiye'nin tarım sektörü, hem iç tüketim hem de ihracat için önemlidir.

Sonuç olarak, tarımsal üretim, global gıda güvenliği ve çevresel sürdürülebilirlik açısından önemlidir. Bu bağlamda, verimliliği artıran ve çevresel etkileri azaltan sürdürülebilir tarım uygulamaları ve teknolojilerinin geliştirilmesi ve uygulanması hayati öneme sahiptir.

3.2. Mısır ve Buğday Yaprak Hastalıkları

Mısır (*Zea mays*), dünyanın en önemli tahıllarından biri olarak geniş bir kullanım alanına sahiptir ve tarihi Orta Amerika'ya dayanır (Tarım ve Orman Bakanlığı, 2008). Avrupa'ya 15. yüzyılda getirilen mısır, bugün gıda, hayvan yemi, endüstriyel ve biyoteknolojik uygulamalar için küresel bir kaynak olarak değerlendirilmektedir. Mısır, dünya genelinde önemli bir gıda, yem ve endüstriyel ürün kaynağı olarak kabul edilir, ancak üretimini tehdit eden çeşitli yaprak hastalıkları vardır. Bu hastalıklar arasında adi pas, gri yaprak

lekesi ve yaprak yanıklığı bulunur, her biri mısır bitkisinin sađlığını ve tarımsal verimliliđi ciddi řekilde etkilemektedir.

Adi pas, *Puccinia sorghi* isimli bir fungal patojen tarafından kaynaklanır ve mısır yapraklarında küçük, yuvarlak, koyu kahverengi ila siyah renkte pas püskülleri řeklinde kendini gösterir. Hastalık genellikle bitkinin alt yapraklarında başlar ve yukarı doğru yayılır. Adi pasın yönetimi, hastalıđa dirençli çeřitlerin ekimi, tarla hijyeninin sađlanması ve gerekirse fungusit uygulamaları ile gerçekleştirilir. Bitki kalıntılarının etkili bir řekilde yönetilmesi ve uygun sulama yöntemleri de hastalığın kontrolünde önemlidir.

Gri yaprak lekesi, *Cercospora zea-maydis* ve *Cercospora zeina* fungal patojenleri tarafından neden olunur. Bu hastalık, yapraklarda uzun, dikdörtgen, gri-kahverengi lekelerin oluşumuyla karakterize edilir ve yaprakların sararmasına, erken dökülmesine neden olabilir. Bu durum, bitkinin fotosentez kapasitesini azaltarak verimi düşürür. Gri yaprak lekesine karşı en etkili yönetim stratejileri arasında, hastalıđa dirençli mısır çeřitlerinin kullanımı, tarla hijyeninin sađlanması, uygun ekim dönemi seçimi ve gerektiğinde fungusitlerin kullanımı bulunur.

Yaprak yanıklığı ise iki ana türden kaynaklanabilir: Kuzey Yaprak Yanıklığı ve Güney Yaprak Yanıklığı. Kuzey Yaprak Yanıklığı, *Setosphaeria turcica* tarafından neden olurken, Güney Yaprak Yanıklığı *Cochliobolus heterostrophus*'un neden olduđu bir hastalıktır. *Bipolaris maydis* ve *Exserohilum turcicum* mantarları tarafından oluşturulan bir hastalıktır. Kuzey Yaprak Yanıklığı, yapraklarda büyük, kama řeklinde, kahverengi veya gri lekelerin oluşumuna neden olur. Güney Yaprak Yanıklığı ise, yapraklarda kırmızımsı-kahverengi lekeler oluşturur ve sıcak, nemli iklimlerde daha yaygındır. Yaprak yanıklığının yönetimi, hastalıđa dirençli çeřitlerin kullanılması, bitki artıklarının düzgün bir řekilde imha edilmesi, uygun ekim yoğunluğunun sađlanması ve gerektiğinde fungusit uygulamaları ile mümkündür. Tarla rotasyonu da bu hastalıkların yönetiminde önemli bir stratejidir. Hastalık, 18-27°C sıcaklık ve yüksek nem koşullarında gelişir ve bitkilerde tozlanma döneminde ağır enfeksiyonlara yol açabilir. Bu durumda %50'ye varan verim kaybı mümkündür. Hastalık, mısırın yanı sıra sorgum ve tatlı sorgum gibi bitkilerde de görülür. Mücadele yöntemleri arasında, hastalıđa karşı dayanıklı çeřitlerin ekilmesi, ekim nöbeti uygulaması, dengeli gübreleme ve hastalıklı bitki artıklarının

temizlenmesi sayılabilir. Ülkemizde bu hastalığa karşı kimyasal mücadele önerilmemektedir (Tarım ve Orman Bakanlığı, 2008).

Bu hastalıkların erken tespiti ve yönetimi, mısır üretiminin sürdürülebilirliği ve verimliliğini korumak için hayati öneme sahiptir. Görüntü işleme ve derin öğrenme tekniklerinin kullanılması, hastalıkların erken aşamalarda tespit edilmesine ve yönetilmesine olanak tanıyarak, çiftçilere ve tarım uzmanlarına zamanında ve etkili müdahaleler yapma şansı verir.

Buğday Durum Tahmin Raporu 2023 göre Polat (2023). 2021/22 pazarlama yılında Türkiye, dünya buğday ekim alanının yaklaşık %3,1'ini oluşturan 67 milyon dekar alanda buğday üretimi gerçekleştirmiştir. Bu dönemde, Türkiye dünya buğday üretiminde 10. sırada, ihracatta ise 8. sırada yer almıştır. Üretimde azalış yaşanırken, toplam kullanımda %1,9 artış gözlemlenmiştir. Konya, buğday ekim alanında ilk sırada yer alırken, Şanlıurfa ve Ankara sırasıyla ikinci ve üçüncü sıradadır. Makarnalık buğday, Türkiye'nin toplam buğday ekim alanının %17,8'ini oluşturmuş, bu alanda 3,1 milyon ton üretim ve yaklaşık 2,6 milyon ton ihracat yapılmıştır. 2020/2021'de 6,9 milyon hektar olan buğday ekim alanı 2021/22'de 6,7 milyon hektara düşmüş, verimde %11,5 azalışla üretim %13,9 azalarak 17,6 milyon tona gerilemiştir.

Buğdayda Pas Hastalıkları ve Mücadele Yöntemleri, Tarım ve Orman Bakanlığı. (2008) göre buday yaprak hastalıkları:

Sarı Pas (*Puccinia striiformis* f. sp. *tritici*), Sarı pas ya da çizgi pası, *Puccinia striiformis* fungal patojeni tarafından neden olur ve özellikle serin ve nemli iklimlerde yaygındır. Ülkemizde buğdayın en yaygın pas hastalıkları arasında yer alır. Bu hastalık özellikle yapraklarda belirgin olmak üzere sap ve başaklarda da görülebilir. Yaprakların üst yüzeyinde sarı renkte, makine dikişini andıran püstüller şeklinde kendini gösterir. Çizgi Pası, bitkinin su ve besin maddesi taşıma kapasitesini azaltır, bu da gelişimini yavaşlatır ve tahıl tanelerinin dolgunluğunu azaltır. Çizgi Pası'nın yönetimi, hastalığa dirençli çeşitlerin kullanımı, uygun ekim zamanlaması ve gerekirse fungisit uygulamaları ile sağlanır. Ayrıca, hastalığın erken tespiti ve hızlı müdahale, yayılmasını önlemek açısından önemlidir. Hastalığın gelişimine yüksek nem ve yağış koşulları katkıda bulunur. Optimal sıcaklık aralığı 10-15°C olarak belirlenmiştir.

Kahverengi Pas (*Puccinia recondita* f. sp. *tritici*), genellikle yapraklarda görülen ve 'Yaprak Pası' olarak da adlandırılan bir hastalıktır. Karakteristik portakal sarısı veya yanık kahverengi püstüller, yaprak yüzeyinde rastgele dağılmıştır. İlkbahar koşullarında, 10-18°C sıcaklık ve yüksek nem, hastalığın enfeksiyon oluşturmaya zemin hazırlar. Türkiye'de bu hastalık özellikle Ege ve Marmara bölgelerindeki sahil şeritlerinde yaygındır.

Kara Pas (*Puccinia graminis* f. sp. *tritici*), buğdayda görülen pas hastalıkları arasında en geç ortaya çıkan türdür. Karakteristik koyu kırmızı veya kahverengi püstüller, yaprağın her iki yüzeyinde, sapta ve başakta oluşur. Hastalığın gelişimi için %96 ve üzeri orantılı nem ve yaklaşık 20°C sıcaklık gereklidir. Bu hastalık, bitkinin kardeşlenmesini azaltır ve dane ağırlığı ile kalitesini düşürür.

Bu hastalıklarla mücadelede alınacak önlemler arasında sık ekimden kaçınma, yabancı ot ve ara konukçu mücadelesi, aşırı azotlu gübre kullanmama, dayanıklı çeşitlerin tercih edilmesi ve belirli koşullarda yeşil aksam ilaçlaması yapılması yer alır.

Buğdayda *Septoria* Yaprak Lekesi (*Septoria tritici*), *Mycosphaerella graminicola* (syn. *Septoria tritici*) fungal patojeni tarafından kaynaklanır ve buğday yapraklarında küçük, koyu renkli lekeler şeklinde belirir. Bu lekeler zamanla büyüyerek birleşir ve yaprağın büyük bir kısmını kaplayabilir. Hastalık, fotosentez kapasitesini azaltır, bitkinin büyümesini yavaşlatır ve dolayısıyla verimi düşürür. Buğdayda önemli bir hastalıktır ve genellikle alt yapraklardan başlayarak üst yapraklara kadar ilerleyebilir. Hastalığın bayrak yaprağına kadar yayılması durumunda, hasat kaybı %25 ile %50 arasında değişebilir. Hastalığın belirtileri, yaprağın yeşil kısımlarından net bir şekilde ayrılan küçük, düzensiz, saman sarısı veya kirli sarı renkli lekelerdir. Hastalığın ilerlemesi ile bu lekeler kül rengine dönüşür. *Septoria* yaprak lekesi ile mücadelede tolerant çeşitlerin ekilmesi, ekim nöbeti uygulaması, derin sürüm yaparak bitki artıklarının toprağa gömülmesi, dengeli gübreleme ve fazla azotlu gübre kullanımından kaçınma önerilmektedir. Kimyasal mücadelede, iklim koşulları ve hastalığın seyrinin dikkate alınarak üst yaprakların, özellikle bayrak yaprağın, hastalıkla bulaşmasını önlemek amacıyla yapılacak yeşil aksam ilaçlaması önem taşır. Ürün toplanmadan 1 ay önce kimyasal müdahalelerin durdurulması gerekmektedir.

Buğdayda görülen pas hastalıkları ve septorya yaprak lekesi, tarım açısından büyük öneme sahiptir. Bu hastalıkların kontrol altına alınması, verim ve kalitenin korunması için elzemdir. Özellikle iklim değişikliklerinin de etkisiyle bu hastalıkların yaygınlığı ve şiddeti artış gösterebilmektedir. Bu nedenle hastalıkların erken teşhisi, etkili mücadele stratejilerinin geliştirilmesi ve uygulanması, hastalıkla mücadelede kritik öneme sahiptir.

Dayanıklı çeşitlerin kullanımı, uygun tarımsal uygulamalar ve gerekli durumlarda kimyasal müdahaleler, hastalıkların kontrolünde etkili yöntemlerdir. Ayrıca, hastalıkların bölgesel dağılımını ve çevresel faktörlerini göz önünde bulundurarak, bölgesel özgünlüklere uygun mücadele stratejilerinin geliştirilmesi gerekmektedir. Bu çerçevede, tarımsal araştırmalar ve çiftçi eğitimleri, hastalıkların etkin kontrolü için önemli bir rol oynamaktadır.

Mısır ve buğday, dünya çapında temel tahıl ürünleri olarak önemli bir role sahiptir. Mısır (*Zea mays*), özellikle Amerika'da köken alan ve geniş bir adaptasyon kapasitesine sahip olan bir bitkidir. Bu bitki, hayvan yemi olarak ve biyoetanol üretiminde kullanılır. Buğday (*Triticum spp.*) ise, dünya genelinde en çok tüketilen tahıllardan biri olup, ekmek, makarna ve diğer gıda ürünlerinin temelini oluşturur (Godfray vd., 2010).

Bu tahılların yaprak hastalıkları, tarım üretiminde önemli bir sorun teşkil eder. Mısır ve buğdayın yaprakları, genellikle mantarlar, bakteriler ve virüsler gibi patojenler tarafından etkilenir ve bu durum bitki sağlığını ve verimini olumsuz etkiler (Savary vd., 2019). Bu hastalıkların etkin yönetimi, hastalığın erken teşhisi ve doğru tarımsal uygulamalarla sağlanabilir. Modern tarım teknolojileri, bu hastalıkların teşhisinde ve yönetiminde önemli bir rol oynamaktadır. Uzaktan algılama ve yapay zeka gibi teknolojiler, hastalıkların erken aşamalarda tespit edilmesine ve etkili müdahale stratejilerinin geliştirilmesine yardımcı olabilir (Bock vd., 2010).

Son olarak, mısır ve buğday hastalıklarının yönetiminde bütüncül bir yaklaşım benimsenmelidir. Bu yaklaşım hem tarımsal uygulamaları hem de çevresel faktörleri içermeli ve sürdürülebilir tarım uygulamalarına odaklanmalıdır. Bu şekilde, mısır ve buğday üretiminde karşılaşılan zorlukların üstesinden gelinmesi ve gelecek nesiller için güvenilir bir gıda kaynağının korunması hedeflenmelidir. Görüntü işleme ve derin öğrenme teknolojileri, bu hastalıkların erken tespitinde ve takibinde önemli bir rol

oynayabilir. Bu teknolojiler, hastalığın belirtilerini hızlı bir şekilde tespit ederek, çiftçilere ve tarım uzmanlarına hastalık yönetimi stratejilerini zamanında uygulama imkânı sunar. Bu da buğday üretiminin korunması ve sürdürülebilirliğinin artırılmasında kritik bir öneme sahiptir.

3.3. Yapay Zeka Kullanılarak Mısır ve Buğday Yapraklarından Hastalık Teşhisinin Sürdürülebilirlik Hedeflerine Katkıları

Yapay zeka (YZ - AI), tarımda devrim yaratma potansiyeline sahip hızla gelişen bir alandır. Görüntü işleme ve derin öğrenme gibi Yapay zeka araçları, mısır ve buğday gibi tarımsal ürünlerde hastalıkların erken ve doğru teşhisinde büyük bir potansiyele sahiptir. Bu teknolojilerin kullanımı, tarımsal üretimi artırmaya, gıda güvenliğini geliştirmeye ve Sürdürülebilir Kalkınma Hedefleri'ne (Sustainable Development Goals – SDG) katkıda bulunmaya yardımcı olabilir (Mohanty vd., 2016; Terentev vd., 2022).

Mısır ve buğday, dünya genelinde temel gıda kaynaklarıdır. Fakat birçok hastalığa karşı hassastırlar. Bu hastalıklar, tarımsal üretimde önemli kayıplara neden olabilir, gıda güvenliğini tehlikeye atabilir ve ekonomiyi olumsuz etkileyebilir (Savary vd., 2019).

Yapay zeka ile mısır ve buğday hastalıklarının teşhisi, SDG'lere önemli katkılar sağlayabilir:

Hedef 2: Açlığa Son:

- **Hastalıkların Erken Teşhisi:** Yapay zeka, hastalık belirtilerini insan gözünden daha erken ve doğru bir şekilde tespit edebilir. Bu sayede, hastalıkların yayılması önenebilir ve tarımsal üretimdeki kayıplar azaltılabilir.
- **Daha Doğru Tedavi:** Yapay zeka, hastalığın türüne ve yaygınlık seviyesine göre en uygun tedavi yöntemini belirlemeye yardımcı olabilir. Bu sayede, kimyasal ilaç kullanımının azaltılması ve çevre kirliliğinin önlenmesi mümkün olabilir.
- **Verim Artışı:** Yapay zeka, hastalıktan arınmış tarlaların ve ürünlerin verimini artırmaya yardımcı olabilir. Bu sayede, gıda güvenliğinin artması ve gıda fiyatlarının düşmesi sağlanabilir.

Hedef 12: Sorumlu Üretim ve Tüketim:

- Kimyasal İlaç Kullanımının Azaltılması: Yapay zeka, hastalıkların erken teşhisi ve doğru tedavisi sayesinde kimyasal ilaç kullanımının önemli ölçüde azalmasına yardımcı olabilir. Bu sayede, çevre kirliliği önlenabilir ve insan sağlığı korunabilir.
- Doğal Kaynakların Korunması: Yapay zeka, su ve toprak gibi doğal kaynakların daha sürdürülebilir bir şekilde kullanılmasına yardımcı olabilir.
- Gıda Atıklarının Azaltılması: Yapay zeka, tarımsal üretimde ve gıda tedarik zincirinde daha fazla verimlilik sağlayarak gıda atıklarının azalmasına yardımcı olabilir.

Hedef 13: İklim Eylemi:

- Hastalık Dirençli Bitki Çeşitlerinin Geliştirilmesi: Yapay zeka, hastalıklara karşı dirençli bitki çeşitlerinin geliştirilmesine yardımcı olabilir. Bu sayede, iklim değişikliğinin tarımsal üretim üzerindeki olumsuz etkilerinin azaltılması mümkün olabilir.
- Karbon Salınımı: Yapay zeka, tarımsal uygulamaların optimize edilmesi yoluyla atmosferden daha fazla karbon dioksitin (CO₂) emilmesine yardımcı olabilir.

Hedef 15: Yaşamı Karada Koruma:

- Biyoçeşitliliğin Korunması: Yapay zeka, tarımsal üretimde daha sürdürülebilir uygulamaların kullanılmasına yardımcı olarak biyoçeşitliliğin korunmasına katkıda bulunabilir.
- Yapay Habitat Oluşturma: Yapay zeka, doğal habitatların tahrip olması nedeniyle yok olma tehlikesi altında olan türler için yapay habitatlar oluşturmak için kullanılabilir.

3.4. Dijital Tarım Evrimi ve Hassas Tarım

Precision Agriculture (PA) - Hassas tarım (HT), tarımsal ekosisteme minimum düzeyde zarar vererek doğal, insani ve mekanik kaynakların potansiyelini en üst düzeye çıkarmayı amaçlayan bir çerçevedir (Zhang vd., 2002).

Dijital tarım, tarımsal üretim süreçlerinin, veri bilimi, yapay zeka (YZ), uzaktan algılama ve diğer dijital teknolojilerle dönüştürülmesidir. Bu evrim, tarımsal faaliyetlerin daha verimli, sürdürülebilir ve çevre dostu hale gelmesini sağlayarak, geleneksel tarım uygulamalarına modern bir alternatif sunar. Hassas tarım ise, dijital tarımın bir alt dalı olarak, tarımsal girdilerin (su, gübre, pestisitler vb.) bitki ve toprak ihtiyaçlarına göre dozajının ayarlanmasını ve tarımsal üretimin her aşamasının optimizasyonunu içerir. Bu bölüm, dijital tarımın evrimi ve hassas tarımın tarımsal üretimdeki önemini ele alacaktır.

Dijital tarımın gelişimi, tarihsel olarak dört aşamalı bir süreç olarak tanımlanabilir. Bu sürecin ilk aşaması olan *Tarım 1.0*, antik çağlarda insan ve hayvan gücüne dayalı el aletlerinin kullanımını kapsar. İkinci aşama olan *Tarım 2.0*'da tarım makinelerinin gelişimiyle toprak işlenmesi, sulanması, ekimi-dikimi ve hasat gibi süreçlerde mekanizasyon ön plana çıkmıştır. Üçüncü aşama, *Tarım 3.0* veya "Hassas Tarım" olarak adlandırılır ve bilgisayar teknolojileri ile elektronik cihazların tarımsal faaliyetlerde kullanımının arttığı bir dönemi ifade eder. Dördüncü aşamada ise "Endüstri 4.0" ile paralel olarak başlayan *Tarım 4.0*, 2011 yılı itibariyle hayatımıza girmiş ve tarımsal dijital dönüşümü, özellikle tarım makineleri arasındaki etkileşimi vurgulamıştır (Şahin 2022).

Hassas Tarım ve Tarım 4.0 ile 5.0, modern tarımsal üretim sistemlerinin tanımını yapar. Bu kavramlar, akıllı tarım, uzaktan algılama ve sayısal tarımı içerir, doğal kaynak kullanımını azaltırken üretkenliği artırmayı hedefler (Martos vd., 2021; Shaikh vd., 2022). HT, veri toplama ve analiziyle kaynak verimliliğini ve sürdürülebilirliği artırma stratejisidir (Çakmakçı vd., 2023).

Tarım 5.0, YZ ve robotik gibi teknolojileri sürdürülebilir tarımda kullanımını vurgular (Saiz-Rubio ve Rovira-Más, 2020). Dijital teknolojilerin tarımsal gıda sistemlerine entegrasyonu olan akıllı tarım, çevresel koşullar ve toprak durumu gibi faktörlerin verimli kullanımını sağlar (Saranya vd., 2023). Tarım 4.0 ve Tarım 5.0, izleme ve kontrol

mekanizmalarını, tahmin ve lojistik uygulamalarını sunar, mobil cihazlarla hastalık tanımlama gibi yenilikleri getirir (Araújo vd., 2021). Bu evrimsel süreç içerisinde dijital tarım, tarımsal süreçlerde verimliliği artırmak, israfı azaltmak, pestisit ve herbisit kullanımını daha iyi kontrol etmek ve çevresel sürdürülebilirlik sağlamak amacıyla çeşitli dijital teknolojilerin entegrasyonunu amaçlamaktadır. Bu entegrasyon, tarım sektörünün daha akıllı, hızlı ve çevre dostu bir şekilde gelişimini sağlamakta ve sürdürülebilir gıda üretimi için kritik bir rol oynamaktadır. Dijital tarım uygulamaları, tarım sektörünün çeşitli yönlerinde teknolojik yeniliklerin entegrasyonunu içeren geniş kapsamlı bir alandır. Bu uygulamalar, tarımsal verimliliği artırma, kaynak yönetimini iyileştirme, çevresel sürdürülebilirliği teşvik etme ve tarım süreçlerini daha etkin bir şekilde yönetme amacı taşır. Modern tarım tekniklerinin bir parçası olarak, akıllı tarım makineleri, İnsansız Hava Araçları (İHA) ve dron'lar, gelişmiş sensör teknolojileri, hassas sulama sistemleri, büyük veri ve analitik çözümler, hassas kimyasal uygulamalar ve Nesnelerin İnterneti (IoT) entegrasyonu gibi teknolojiler ön plana çıkmaktadır. Bu teknolojiler, tarımsal üretim süreçlerini otomatikleştirmek, tarımsal faaliyetlerin izlenmesini ve yönetimini iyileştirmek ve tarımsal karar alma süreçlerini daha bilgilendirici ve veriye dayalı hale getirmek için kullanılmaktadır. Bu sayede, dijital tarım, geleneksel tarım metodolojilerine kıyasla, daha sürdürülebilir, verimli ve etkili bir tarım sektörünün gelişimine önemli katkılar sağlamaktadır (Şahin, 2022).

İnsansız hava araçları (İHA), tarımda yabancı ot tespiti ve yönetiminde etkili olarak kullanılır (Maes ve Steppe, 2019). İHA ve uzaktan algılama teknikleri, yüksek çözünürlüklü görüntülerle tespiti kolaylaştırır (Barrero vd., 2018). HT'de İHA, bitki modelleme ve verim yönetiminde önemli bir rol oynar (Boursianis vd., 2022). Sonuç olarak, YZ ve dijital tarım teknolojileri, tarımın geleceğinde önemli bir dönüşüm sağlar ve geleneksel tarım yöntemlerini akıllı tarıma evriltir.

3.5. Yapay Zekâ ve Tarihsel Gelişimi

Yapay zekâ (YZ) - (Artificial Intelligence - AI), bilgisayar sistemlerinin insan zekâsına benzer şekilde düşünmesini, öğrenmesini ve problem çözmesini sağlayan bir alanı kapsar. Yapay zekâ, insan zekâsını taklit etmeyi amaçlar ve insan benzeri düşünme, anlam çıkarma, genellemeler yapabilme ve geçmiş tecrübelerden öğrenme gibi yetenekleri

makinelere aktarır. Oxford İngilizce Sözlüğü'nde yapay zeka, karar alma, görsel algı, konuşma tanıma ve dil çevirisi gibi insan zekâsını gerektiren işleri yapabilen bilgisayar sistemleri olarak açıklanır. Her iki tanım da yapay zekanın, bir komutu yerine getirirken öğrenme yeteneğine sahip bilgisayar sistemleri olduğunu vurgular. Yapay zeka, insanlara kıyasla daha zeki çalışabilir, hızlı düşünür ve daha kesin kararlar alabilir (Yılmaz, 2023). YZ'nin tarihsel gelişimi oldukça uzun bir geçmişe sahiptir. İnsanlar, antik çağlardan beri insan yapımı makineler ve otomatlar üzerinde çalışmışlardır. Yapay zekâ teknolojinin hızla ilerlemesiyle birlikte, disiplinler arası mühendislik problemlerinin çözümünde sıkça başvurulan bir alan haline gelmiştir. Bu teknolojik ilerleme, YZ'nin son yıllarda popülerliğini artırmasına neden olmuştur.

Yapay zeka, geçmişten günümüze kadar uzanan ve sürekli gelişen bir teknolojidir. Yapay zekanın tarihsel kökenleri, Antik Yunan, Mısır ve Çin efsanelerinde bulunan insan benzeri düşünen ve hareket edebilen düşsel varlıklara kadar uzanır. Bu tarihsel bağlam, yapay zekanın sadece modern bir fenomen olmadığını, aynı zamanda insan zekâsının ve yaratıcılığının uzun bir tarihini olduğunu göstermektedir. Şekil 3.1'de açıklandığı gibi, yapay zeka üç ana bileşen üzerine inşa edilmiştir: veri setleri, öğrenme algoritmaları ve karar verme mekanizmaları. Yapay zekâ sistemlerinde veri setleri, metin ve görüntü verileri, zaman ve mesafe ölçümleri, video düzenlemeleri gibi çeşitli biçimlerde toplanır. Öğrenme algoritmaları bakımından, yapay zekâ yapay sinir ağlarından makine öğrenmesine ve derin öğrenmeye kadar çeşitli alt kategorileri kapsar. Yapay zekânın öğrenme algoritmaları karmaşık yapılar sergileyebilir, ancak temelinde algoritma ve programlama ilkelerine dayanır.



Şekil 3.1. Yapay zekâ'nın temel bileşenleri

3.5.1. Antik çağlardan modern çağa yapay zekâ

Yapay zekâ kavramı, modern teknolojinin gelişimiyle birlikte ortaya çıkmamıştır; aslında, insanlık tarihindeki en eski dönemlerden beri var olmuştur. Antik çağlardan

itibaren, insanlar insan yapımı makineler ve otomatlar tasarlamış ve üretmiştir. Örneğin, Antik Yunan'da, mekanik cihazlar ve otomatlar, matematiksel problemleri çözmek veya eğlence amacıyla kullanılmıştır. Orta Çağ'da, otomatlar ve mekanik cihazlar, saatler ve müzik kutuları gibi karmaşık sistemler olarak geliştirilmiştir. Yunan mucit Ktesibios (M.Ö. 285 – 222), zamanı gösteren Clepsydra (Su Hırsızı) adlı saati icat etmiş, bu icat tarihteki ilk ilkel robotik ve otomasyon örneği olarak kabul edilir.

El Cezeri, 12. yüzyılda yaşamış bir İslam bilgini ve mucittir. Özellikle mekanik ve otomatik aletlerin tasarımı konusundaki çalışmalarıyla tanınmaktadır. El Cezeri'nin en ünlü eseri "El-Cami beyne'l-İlm ve'l-Amel en-Nafi fi Sına'at el-Hiyel" (Bilgi ve Pratik Arasındaki Bağ: Mekanik Aletler Sanatında Faydalı Bilgiler) adlı kitabıdır. El-Cami adlı eseri, mekanik aletlerin tasarımı ve çalışma prensipleri hakkında detaylı bilgiler içerir. Bu eserde, suyun kullanılmasıyla çalışan bir dizi otomatik aletin tasarımını ve işleyişini açıklar. El Cezeri'nin tasarladığı otomatlar arasında suyun basınç gücünü kullanan mekanizmalar bulunmaktadır (Çırak ve Yörük, 2016). Örneğin, El Cezeri'nin tasarladığı otomatik bir saat, suyun basınç gücünü kullanarak çalışır. Bu saat, bir su deposuyla bağlantılı bir mekanizma kullanır ve suyun basıncıyla saat işaretleri hareket ettirilir. Ayrıca, El Cezeri'nin tasarladığı otomatik çalgılar da suyun basıncıyla çalışabilir. Bu çalgılar, suyun akışıyla hareket eden pistonlar ve diğer mekanizmalar kullanarak müzik yapabilir veya gösteri amaçlı hareketler gerçekleştirebilir. El Cezeri'nin icatları, o dönemdeki bilgi birikimi ve teknolojiye dayanarak oldukça ileri seviyedeydi. Onun çalışmaları, mekanik mühendislik ve otomatik sistemlerin gelişimine büyük katkıda bulunmuştur. Bugün bile, El Cezeri'nin tasarladığı bazı otomatik aletlerin yeniden inşası ve çalıştırılması, geçmişteki bilgelik ve mühendislik becerilerine olan hayranlığımızı arttırmaktadır. İslam bilim insanı El Cezeri, çeşitli otomatlar icat etmiş ve bu otomatlar için su basıncı kullanmıştır.

3.5.2. Turing testi ve yapay zekânın felsefi temelleri

Alan Turing, "Computing Machinery and Intelligence" adlı makalesinde makinelerin düşünüp düşünemeyeceğini tartışmış ve Turing Testi kavramını geliştirmiştir (Turing, 1950). Yapay zekâ (YZ) alanındaki felsefi tartışmaların merkezinde, Alan Turing'in önerdiği Turing Testi bulunmaktadır. Test, bir insanın bir bilgisayar programıyla bir

sohbet yoluyla etkileşime geçmesini içerir ve insanın programın gerçekten insan gibi davranıp davranmadığını belirlemesini sağlar. Felsefi açıdan, Turing Testi YZ'nin ne kadar "akıllı" veya "bilinçli" olabileceğini sorgular. Bu test, YZ'nin insan zekâsını tam olarak simüle edip edemeyeceği konusunda derin düşüncelere yol açmıştır.

3.5.3. Modern yapay zeka kavramının doğuşu ve gelişimi

Modern yapay zeka kavramının doğuşu ve gelişimi, bilgisayar biliminin ve bilişsel psikolojinin derinlemesine araştırılması ve geliştirilmesiyle yakından ilişkilidir. Modern yapay zeka, insan zekâsını taklit etmeyi amaçlayan bilgisayar sistemlerinin tasarımı ve uygulanmasını içeren bir alanı ifade etmektedir. Bu kavramın doğuşu, 20. yüzyılın ortalarına doğru bilgisayar teknolojisinin hızla ilerlemesiyle gerçekleşmiştir. Alanın erken dönemlerinde, bilim insanları ve matematikçiler, insan zekâsının temel işlevlerini bilgisayarlar aracılığıyla nasıl taklit edebileceklerini araştırmaya başladılar. Bu dönemde, John McCarthy, Marvin Minsky, Alan Turing ve diğerleri gibi önde gelen bilim insanları, yapay zekâ alanının kuruluşunda önemli roller üstlendiler. Claude Elwood Shannon, 1950'lerde bilgisayarların satranç oynayabileceğini belirtmiştir (Shannon, 1950). Daha sonra 1956'da McCarthy'nin önderliğinde gerçekleşen Dartmouth Konferansı, yapay zekânın resmi olarak tanımlandığı ve araştırma ve geliştirme çalışmalarının başladığı bir dönüm noktası olmuştur (McCarthy, 1979).

1960'ların başlarından itibaren, yapay zeka alanı hızla genişlemiş ve çeşitli alt alanlar ve yaklaşımlar geliştirilmiştir. Bu dönemde, uzman sistemler, sembolik yapay zeka ve makine öğrenmesi gibi yeni teknikler ve metodolojiler ortaya çıkmıştır. Özellikle, makine öğrenmesi alanı, bilgisayar sistemlerinin verilerden öğrenerek gelişmelerini sağlayan önemli bir alt alan haline gelmiştir.

1970'ler ve 1980'ler boyunca, yapay zeka araştırmaları hız kesmeden devam etti ve bilgisayarlar giderek daha karmaşık görevleri yerine getirebilecek hale geldi. Ancak, bu dönemde yapay zeka alanı büyük bir hayal kırıklığı yaşadı ve "Yapay Zeka Kışı" olarak adlandırılan bir döneme girdi. Bilgisayarlar üzerinde yapılan araştırmaların getirdiği yüksek beklentilerin gerçekleşmemesi, bu dönemde yapay zeka araştırmalarının finansmanının azalmasına ve ilginin kaybolmasına neden oldu. Ancak, 21. yüzyılın başlarında, yapay zeka alanı büyük bir canlanma yaşadı. Bu canlanma, büyük veri, derin

öğrenme, yapay sinir ağları ve nesnelerin interneti gibi yeni teknolojilerin geliştirilmesi ve benimsenmesiyle tetiklendi. 21. yüzyılın başlarında yapay zeka alanında yaşanan büyük canlanmanın altında yatan ana sebep, birkaç faktörün bir araya gelmesidir. Bunlar arasında şunları sayabiliriz:

Büyük Veri: Teknoloji ve internet kullanımındaki patlama, büyük miktarda verinin üretilmesine ve depolanmasına yol açmıştır. Bu veri miktarının artması, yapay zeka algoritmalarının daha doğru ve güçlü hale gelmesini sağlamıştır.

Derin Öğrenme: Derin öğrenme, yapay zeka modellerinin karmaşık veri yapılarını ve desenleri tanıma yeteneğini artıran bir tekniktir. Bu teknik, yapay zekanın daha önce görülmemiş seviyede başarı elde etmesine olanak tanımıştır.

Yapay Sinir Ağları: Yapay sinir ağları, insan beyninin işleyişine benzer şekilde bilgi işleme yeteneğine sahip yapay sistemlerdir. Bu sinir ağları, yapay zeka uygulamalarında önemli bir rol oynamaktadır ve karmaşık problemleri çözmek için kullanılmaktadır.


Nesnelerin İnterneti (IoT): Nesnelerin İnterneti, fiziksel cihazların internete bağlanmasını sağlayan bir teknolojidir. Bu sayede, milyarlarca cihazdan gelen veriler toplanabilir ve analiz edilebilir, bu da yapay zekanın daha fazla veriye erişmesini sağlar.

Bu faktörlerin bir araya gelmesi, yapay zeka alanında büyük bir ivme kazanılmasını sağlamış böylelikle yapay zekanın birçok sektörde daha yaygın bir şekilde kullanılmasına ve geliştirilmesine olanak tanımıştır.

Yapay zeka, antik dünyadan modern dünyaya kadar uzanan bir yolculuğa sahiptir. Bu yolculuk, yapay zekanın sadece son teknolojik gelişmelerle sınırlı olmadığını, insan zekâsı ve yaratıcılığının uzun bir tarihini temsil ettiğini göstermektedir. Antik dünyadan alınan ilhamla modern dünyada gerçekleştirilen çalışmalar, yapay zekanın sürekli yönünü yönlendirmektedir. Bu tarihsel bakış açısı, yapay zekanın geleceğini daha iyi anlamamıza ve bu alanın potansiyelini daha iyi değerlendirmemize olanak tanır.

Yapay zekâ sistemleri, problem çözümü için çeşitli otomatik karar verme araçlarına sahiptir. Bu sistemler, veri girişi yapıldığında, eğitilmiş matematiksel algoritmalar aracılığıyla bir uzmanın alacağı kararları simüle eder. Yapay zeka modelleri, karar alma

sürecinin daha iyi anlaşılmasına da yardımcı olur. Bu modeller, en etkili kararı vermek veya maliyetleri minimize etmek için geniş veri setlerini işler. Çeşitli kaynaklardan gelen verileri analiz eden yapay zekâ modeli, bir uzman ekibinin yapacağı karar verme sürecini tek başına gerçekleştirebilir. Şekil 3.2'de yapay zekâ ile problem modelleme adımları gösterilmektedir.



Şekil 3.2. Yapay zekâ problem modelleme

- **Problem Tanımlanması:** Yapay zekâ çözümlerinde, öncelikle problem sınıflandırma, regresyon ya da kümeleme gibi türlere ayrılır. Örneğin, bitkisel tarım ürünlerinde hastalık tespiti bir sınıflandırma problemi olarak değerlendirilirken, bitki büyümesi ile ilgili verileri kullanarak verim tahminlemesi yapmak bir regresyon problemi olarak görülür.
- **Veri Toplama:** Problemin çözümünde, Kaggle, Mendeley Data gibi açık erişim kaynaklarından ya da özel olarak toplanan veri setlerinden faydalanılır. Bu veriler, analiz ve modelleme için temel oluşturur.
- **Veri Ön İşleme:** Toplanmış veriler üzerinde, eksik veya anlamsız verileri düzeltme gibi ön işleme adımları uygulanarak yapay zekâda oluşabilecek problemler önlenir. Veri ön işlemede veriler önce sıralanır, sonra aykırı veya gürültülü veriler kümeleme algoritmalarıyla tespit edilebilir. Eksik verilerin tamamlanmasında ise regresyon yöntemleri kullanılabilir.
- **Eğitim:** Veri ön işleme sonrasında, eğitim için ayrılan verilerle yapay zekâ modelleri eğitilir.
- **Test:** Eğitilen modeller, test verileri kullanılarak değerlendirilir ve anlamlı sonuçlar elde edilir.
- **Sonuç:** Test sürecinde en iyi performansı gösteren model seçilir.

3.5.4. Günümüzde yapay zeka

Günümüzde yapay zeka (YZ) kavramı, bilgisayar bilimi ve mühendisliğindeki önemli bir alanı ifade eder. Yapay zeka, bilgisayar sistemlerinin insan zekasıyla benzer yeteneklere sahip olmasını sağlayan bir disiplindir. Bu, problem çözme, öğrenme, algılama, dil işleme, karar verme ve daha birçok zekâsal yeteneği içerebilir. Yapay zeka teknikleri, büyük veri analitiği, makine öğrenimi, derin öğrenme, doğal dil işleme ve uzman sistemler gibi çeşitli alt alanları kapsar.

Günümüzde yapay zeka, birçok alanda çeşitli uygulamalara sahiptir. Örneğin, otomotiv endüstrisinde sürücüsüz araçlar, sağlık sektöründe tıbbi teşhis ve tedavi planlaması, finans sektöründe risk yönetimi, perakende sektöründe kişiselleştirilmiş pazarlama ve daha birçok alanda yapay zeka teknolojileri kullanılmaktadır. Bazı uygulamalar örnek verilecek olursa:

- **Sağlık Sektörü:**

Tıbbi görüntü analizi: Yapay zeka, radyoloji ve patoloji gibi alanlarda tıbbi görüntülerin analiz edilmesinde kullanılır. Örneğin, kanser tespiti ve teşhisinde derin öğrenme teknikleri kullanılır.

Hastane yönetimi: Yapay zeka, hastane verilerinin analiz edilmesi ve hastane kaynaklarının daha etkin bir şekilde yönetilmesi için kullanılır. Örneğin, hasta yoğunluğunu tahmin etme ve kaynak planlaması yapma.

- **Finans Sektörü:**

Risk yönetimi: Yapay zeka, finansal verilerin analiz edilmesiyle kredi riski, piyasa riski ve operasyonel risk gibi risklerin belirlenmesine yardımcı olur.

Yatırım danışmanlığı: Yapay zeka, yatırım stratejileri geliştirmek için büyük veri analitiği ve makine öğrenimi tekniklerini kullanır.

- **Perakende Sektörü:**

Kişiselleştirilmiş pazarlama: Yapay zeka, müşteri davranışlarını analiz ederek kişiselleştirilmiş pazarlama kampanyaları oluşturur.

Stok yönetimi: Yapay zeka, talep tahmini yaparak stok seviyelerini optimize eder ve stok yönetim süreçlerini iyileştirir.

- **Otomotiv Sektörü:**

Sürücüsüz araçlar: Yapay zeka, otonom araçların algılaması, karar vermesi ve hareket etmesi için kullanılır. Örneğin, radar ve kamera sistemleriyle çevresel algılama sağlar.

- **Eğitim Sektörü:**

Öğrenci başarısını tahmin etme: Yapay zeka, öğrenci performans verilerini analiz ederek öğrenci başarısını tahmin eder ve öğretmenlere öneriler sunar.

Öğrenme yönetimi: Yapay zeka, öğrencilerin öğrenme süreçlerini izler ve onlara kişiselleştirilmiş eğitim içerikleri sunar.

- **Tarım Sektörü:**

Verimlilik artışı: Yapay zeka, tarım verilerini analiz ederek verimliliği artırır ve sürdürülebilir tarım uygulamalarını destekler. Örneğin, çiftçilere tarım alanlarında hastalık tespiti, sulama ve gübreleme tavsiyeleri sunar.

Bu sektörlerde yapay zeka uygulamaları, sürekli olarak geliştirilmekte ve yenilikçi çözümlerle desteklenmektedir. Her sektörde, yapay zeka teknolojilerinin kullanımıyla verimlilik artışı, maliyet tasarrufu ve rekabet avantajı elde etmek amaçlanmaktadır.

Yapay zeka alanında son yıllarda yaşanan hızlı gelişmeler, derin öğrenme ve büyük veri analitiği gibi yeni tekniklerin ortaya çıkmasına olanak sağlamıştır. Bu teknikler, daha karmaşık ve büyük ölçekli veri setlerini işleyebilme yeteneği ve daha kesin sonuçlar elde etme potansiyeli sunmaktadır. Ancak yapay zeka teknolojilerinin kullanımıyla ilgili bazı endişeler de bulunmaktadır. Özellikle veri gizliliği, güvenlik, etik ve işgücü değişimi gibi konular, yapay zeka teknolojilerinin yaygınlaşmasıyla birlikte önemli hale gelmektedir. Bu bağlamda Yuval Noah Harari'ye göre, yapay zeka ile ilgili en büyük sorunlar, risklerin tam olarak anlaşılamamasından kaynaklanmaktadır. İnsanlık, kendi zekasını ve gücünü aşan bir varlık yaratmış olabilir ve bu, kontrolün kaybedilmesi riskini içerir. Harari, bu durumu finans sektörü üzerinden örnekleyerek açıklar. Diken (2023) Harari'nin belirttiği üzere "Yapay zeka yepyeni finansal cihazlar geliştirebilir, bunlar insanların anlayabileceğinin ötesinde olabilir ve 20 yıl sonra hiçbir insan, finansal sistemin nasıl

işlediğini anlayamayabilir. Tamamen yapay zekaya güvenmek zorunda kalabiliriz”. Bu nedenle, yapay zeka alanında çalışan uzmanlar, teknolojinin güvenli ve etik kullanımını sağlamak için çeşitli politika ve yönergeler geliştirmeye de odaklanmaktadır.

3.6. Tarımda Yapay Zeka Uygulamaları

Ziraat, insanların hayatta kalabilmeleri için gerekli olan temel ve zorunlu ihtiyaçların karşılanmasında hayati bir role sahip olan faaliyetlerden biridir. Bitki ve hayvan bazlı üretim yöntemlerini içeren ziraat, insanların sağlıklı ve dengeli bir şekilde beslenmesine, ülkenin ekonomik gelirinin ve iş olanaklarının artmasına, endüstriyel üretim için ham madde teminine, ekonomik gelişime katkı sağlaması ve dış ticaret aracılığıyla döviz kazanılmasına önemli sosyal ve ekonomik katkılarda bulunur. Ancak, ziraat sektörü son zamanlarda küresel piyasa değişiklikleri, ekonomik krizler, kuraklık ve küresel ısınmanın yol açtığı iklim değişiklikleri, hayvan hastalıkları, tarımsal ürünlerin biyoyakıt gibi alternatif kullanım alanlarının artması, tarım arazilerinin bölünmüş yapısı ve eğitim eksiklikleri gibi olumsuz faktörlerden etkilenmektedir. Ayrıca, dünya nüfusunun hızlı artışı ve şehirleşmenin yaygınlaşması sonucu tarım alanları daralmakta, kişi başına düşen tarım arazisi ve su gibi temel doğal kaynaklar giderek azalmaktadır (Özgüven, 2018).

Tarımda yapay zeka uygulamaları, günümüzde tarım sektöründe önemli bir dönüşümü tetiklemektedir. Bu uygulamalar, tarımsal üretimde verimliliği artırmak, kaynakları daha etkin kullanmak, çevresel etkileri azaltmak ve gıda güvenliğini sağlamak gibi önemli amaçlara hizmet etmektedir. Akademik literatürde yapılan çalışmalar, bu alandaki potansiyeli ve önemi vurgulamaktadır. Bu teknolojiler, çiftçilere ve tarım topluluklarına, enerji yönetimi, hastalık tespiti, haşere tespiti, ürün izleme ve görevlerin otomatikleştirilmesi gibi alanlarda yardımcı olmakta, çiftlik hayvanlarının sağlık takibini ve hassas tarım uygulamalarını kolaylaştırmaktadır. Ayrıca, insan-makine iş birliği, otomatik ayıklama, arıza tespiti ve güvenlik amaçları için de etkin çözümler sunmaktadır. Bu uygulamalar, tarım sektörünü daha sürdürülebilir ve verimli hale getirirken, kaynak kullanımını da etkin bir şekilde yönetilmesine katkı sağlamaktadır.

Öncelikle, yapay zeka uygulamalarının tarımsal üretimdeki önemi, veri analizi ve tahmin yeteneklerinin kullanılmasıyla ortaya çıkmaktadır. Sensörler aracılığıyla toplanan verilerin yapay zeka algoritmalarıyla analiz edilmesi, tarım alanlarında su ve gübre

kullanımını optimize ederek kaynakların verimli bir şekilde kullanılmasını sağlama potansiyeline sahiptir. Ayrıca, hava ve toprak koşullarını tahmin etme yeteneği sayesinde, çiftçilere doğru zamanda doğru müdahaleleri yapma imkânı verirken ürün verimliliğini artmasını sağlamaktadır.

Yapay zeka ayrıca otomatik tarım makinelerinin geliştirilmesinde de önemli bir rol oynamaktadır. Bu makineler, görüntü işleme ve makine öğrenimi tekniklerini kullanarak, yabancı ot tespiti, hastalık teşhisi ve hasat süreçlerinde verimliliği artırmak için çiftçilere yardımcı olabilir. Bu sayede iş gücü maliyetleri azalırken, işçilik yoğun süreçlerin verimliliği de artırılmış olacaktır.

Yapay zeka, tarım sektöründe önemli bir dönüşüm yaratma potansiyeline sahip bir teknoloji olarak değerlendirilmektedir. Yapay zeka uygulamalarının tarım sektöründe ileride daha da büyük katkılar sağlaması beklenmektedir. Özellikle, büyük veri analitiği ve makine öğrenimi modellerinin daha da geliştirilmesiyle, tarımsal süreçlerin daha hassas bir şekilde yönetilmesi mümkün olacaktır. Ayrıca, iklim değişikliği gibi küresel zorluklarla başa çıkmak için yapay zeka destekli tarım teknolojilerinin kullanılması, tarımsal üretimi daha sürdürülebilir hale getirebilir.

Sonuç olarak, tarımda yapay zeka uygulamaları, geleneksel yöntemlere kıyasla, verimliliği artırarak ve kaynakları daha etkin bir şekilde kullanarak tarım sektöründe önemli bir dönüşümü tetiklemektedir. Bu teknolojilerin geliştirilmesi ve yaygınlaştırılması, küresel gıda güvenliği ve sürdürülebilir tarımın sağlanmasına önemli katkılar sağlayacaktır. Tablo 3.1’de yapay zeka yöntemleri kullanılarak yürütülen tarımsal araştırmaların örnekleri sunulmuştur (Terzi vd., 2019).

Bulanık Mantık: Bulanık mantık uygulamaları, tarım alanında karar verme süreçlerini optimize etmekte ve verimliliği artırmaktadır. Özellikle sulama yönetimi ve sera sistemlerinde, hassas kontrol ve adaptasyon sağlamaktadır. Sulama ve su kaynaklarının tespiti gibi alanlarda yapılan çalışmalar, bulanık mantığın tarımda su kullanımını optimize ederek kaynakların daha etkin kullanılmasına olanak sağladığını göstermektedir.

Yapay Sinir Ağları: Enerji tüketimi, hastalık sınıflandırılması ve üretim yönetimi gibi konularda yapay sinir ağlarının kullanılması, tarım sektöründe verimliliği artırıcı ve maliyet düşürücü etkiler yaratmaktadır. Özellikle hastalık tanıma ve sınıflandırma konusundaki çalışmalar, tarımsal ürünlerin sağlığını korumak ve hastalıkları erken teşhis etmek açısından önem taşımaktadır.

Tablo 3.1. Yapay zeka yöntemleri ile tarım araştırmalarına örnekler

Yapay Zeka Teknikleri	Çalışma Konuları	Yapılan Çalışmalar
Bulanık Mantık	Sulama Yönetimi	(Martha vd., 2016)
	Su Kaynaklarının Tespiti	(Faridi vd., 2018)
	Tarımsal Potansiyelin Belirlenmesi	(Kurniasih vd., 2018)
	Üretimde Karar Destek Sistemi	(Kale ve Patil, 2019)
	Sera Sistemleri	(Ali vd., 2018)
Yapay Sinir Ağları	Üretimde Enerji Tüketimi	(Khoshnevisan vd., 2015)
	Hastalık Sınıflandırılması	(Oppenheim ve Shani, 2017)
	Üretim Yönetimi	(Kamilaris ve Prenafeta, 2018)
	Tarımsal Atık İşlenmesi	(Liu vd., 2018; Khoshroo vd., 2018)
	Ürün Kurutma İşlemi	(Khawas vd., 2016)
Genetik Algoritma	Arazi Kullanım Optimizasyonu	(Li ve Parrott, 2016)
	Toprak Mekanik Direnç Tahmini	(Hosseini vd., 2016)
	Otomatik Arazi Sınıflandırılması	(Haklı ve Uğuz, 2017)
	Hastalık Tespiti	(Arya vd., 2018)
Uzman Sistemler	Yabancı Ot Tespiti	(Montalvo vd., 2013)
	Yeşillik Tanımlama	(Romeo vd., 2013)
	Tarım Makinalarında Durum Tespiti	(Martinez vd., 2015)
	Hayvansal Üretimde Sistem Analizi	(Vásquez vd., 2019)
	Arazi Tahsisi Yapılması	(Haklı vd., 2018)
Karma Algoritmaları	Tarımda Taahhüt İşlerini Planlama	(Alaiso vd., 2013)
	Sulama Yönetimi	(Nguyen vd., 2017)
	Hastalık Tanıma ve Sınıflandırma	(Zhang vd., 2018)
	Toprak Azot İçeriği Tahmini	(Zhang vd., 2019)
	Böcek Sınıflandırması ve Tespiti	(Kasinathan vd., 2021)

Genetik Algoritma: Genetik algoritma, tarımda özellikle kaynak optimizasyonu ve verimlilik artırma konularında etkili olmaktadır. Arazi kullanımı ve ürün kurutma işlemlerindeki uygulamaları, tarımsal süreçlerin daha verimli ve sürdürülebilir olmasına katkıda bulunmaktadır.


Uzman Sistemler: Tarımda karşılaşılan karmaşık problemlerin çözümünde uzman sistemlerin kullanılması, karar verme süreçlerini desteklemekte ve verimliliği artırmaktadır. Yabancı ot tespiti ve tarım makinelerinde durum tespiti gibi uygulamalar, tarımsal faaliyetlerin daha etkin ve verimli bir şekilde yönetilmesine yardımcı olmaktadır.

Karınca Algoritmaları: Bu algoritmanın tarımda kullanımı, özellikle planlama ve optimizasyon konularında önem taşımaktadır. Tarımsal işlerin planlanması ve yönetilmesindeki etkinliği, tarımsal üretimin verimliliğini ve sürdürülebilirliğini artırmada önemli bir rol oynamaktadır.

Bu çıkarımlar, yapay zekanın tarımda karşılaşılan çeşitli zorlukları aşmada ve sektörün sürdürülebilir bir şekilde gelişmesine katkıda bulunmada önemli bir araç olduğunu göstermektedir. Yapay zeka uygulamalarının bu şekilde tarıma entegre edilmesi, verimliliği artırma, maliyetleri düşürme ve çevresel sürdürülebilirlik açısından önemli faydalar sağlamaktadır.

3.7. Makine Öğrenmesi

Yapay zekâ genellikle bir dizi alt bileşenden oluşur. Yapay zekayı oluşturan temel alt bileşenler Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Yapay zekâ yöntemleri

Makine öğrenmesi, yapay zekanın bir alt dalı olarak tanımlanabilir ve verilerden öğrenme ile tahmin yapma yeteneklerini geliştiren algoritmalar ve istatistiksel modellerle çalışmaktadır. Arthur Samuel, 1959 yılında makine öğrenmesini, "bilgisayarların açıkça programlanmadan öğrenme yeteneğini kazandıran çalışma alanı" olarak tanımlamıştır (Samuel, 1959). Bu alt bileşen, sınıflandırma, regresyon, kümeleme gibi çeşitli görevleri yerine getirmek için kullanılır. Makine öğrenimi ayrıca örüntü tanıma, ses tanıma ve dil işleme gibi alanlarda da etkindir (Bishop, 2006). Bu alanlarda kullanılan makine öğrenimi teknikleri, gelişmiş tahmin ve analiz yetenekleri sunarak, bu disiplinlerin gelişimine katkıda bulunmaktadır.

Makine öğrenimi süreci, yedi temel adımdan oluşur: veri toplama, veri hazırlama, model seçimi, eğitim, değerlendirme, hiper parametre ayarlama ve tahmin (Raschka, 2016). Bu adımlar, makine öğrenimi algoritmalarının etkili bir şekilde uygulanmasında kritik rol oynamaktadır.

3.7.1. Terminoloji

Model: Görevin sayısal temsili olarak ifade edilir.

Özellik (Feature): Veri kümesindeki ölçülebilir parametrelerdir.

Özellik Vektörü: Birden fazla özelliğin kombinasyonudur.

Eğitim: Modelin veri seti üzerinde eğitilmesi sürecidir.

Hedef (Etiket): Modelin tahmin etmesi gereken değeri temsil eder.

Tahmin: Modelin veriye dayalı çıktı üretmesidir.

Aşırı Uyum (Overfitting) ve Yetersiz Uyum (Underfitting): Modelin verilere uyumuyla ilgili olası sorunlardır.

3.8. Derin Öğrenme

Derin öğrenme, yapay zekanın ileri bir alt dalı olarak, çok katmanlı sinir ağlarını kullanarak karmaşık görevleri gerçekleştirmek için makine öğrenimi yöntemlerini kullanır. Derin öğrenme, büyük miktarda veri ile karmaşık desenleri keşfedebilir ve çözebilir. Derin öğrenme algoritmalarının temel amacı, veriden anlamlı özellikler çıkarmaktır. Makine öğrenmesinin çok katmanlı yapısını temel alarak büyük ve karmaşık veri kümelerini işleme ile sofistike modeller yapılımasını sağlar.


Günümüzde derin öğrenme modelleri, bilgisayarlı görüş, nesne tanıma, tıbbi görüntüleme, otomatik sürüş gibi birçok alanda devrim niteliğinde ilerlemeler sağlamaktadır. Bu ilerlemelerin arkasında, derin öğrenme mimarileri olarak adlandırılan güçlü ve etkili yapılar bulunmaktadır. Artan veri boyutları ve işlem kapasiteleriyle birlikte derin öğrenme algoritmaları, karmaşık problemlerin çözümünde derin öğrenme kullanılmaktadır. Bu, teknolojik gelişmelerin ve donanım yeniliklerinin bir sonucudur. Derin öğrenme ağlarında, her katman öncekinden daha karmaşık özellikleri işler. Girdi verisi sırasıyla işlenerek nihai tahminler üretilir. Tahminler ve gerçek veriler arasındaki fark, kayıp fonksiyonu ile ölçülür.

Derin öğrenme, bilgisayarlı görüş ve doğal dil işleme gibi alanlarda da etkileyici sonuçlar elde ederek, yapay zeka araştırmalarında öncülük yapmaktadır. Bu gelişmeler, yapay zekanın gelecekteki yönünü şekillendirmektedir.

Derin öğrenme, verilerin birden çok soyutlama düzeyinde temsillerinin öğrenilmesine olanak sağlayan hesaplama modelleridir. Görsel nesne tanıma, konuşma tanıma ve nesne algılama gibi alanlarda önemli katkılar sağlamıştır (LeCun vd., 2015). Modeller arasında LeNet, AlexNet, ZFNet, VGGNet, GoogLeNet ve ResNet bulunmaktadır (İnik ve Ülker, 2017). Bu çalışmada, mısır için ResNet modeli ve buğday için YOLO algoritması tercih edilmiştir.

3.8.1. Derin öğrenme ile makine öğrenmesi arasındaki ilişki

Derin öğrenme ve makine öğrenmesi, yapay zeka alanında iki önemli alt kategoriyi oluşturur. Derin öğrenme ile makine öğrenmesi arasındaki ilişki Şekil 3.4'te verilmiştir (Intersog, 2021). Makine öğrenimi etiketli resimlerden öğrenmek için akıllı araçlar kullanırken, derin öğrenme kendi kendine öğrenen akıllı bir ağ oluşturur. Her iki yol da bilgisayarların resimlerdeki ev, kedi ve köpek gibi şeyleri tanımasına yardımcı olur.



Şekil 3.4. Makine öğrenmesi ve derin öğrenme genel gösterimi

Derin öğrenme ile makine öğrenmesi arasındaki ana farkların ne olduğunu aşağıdaki gibi özetlenmiştir. Her iki yöntem de farklı türde görevler için kullanılabilir ve avantajlarına göre seçilir. Bu iki yaklaşım genellikle birbirinin yerine kullanılsa da karmaşık sorunları çözmek ve verilerden değerli içgörüler elde etmek için farklı metodolojiler sunmaktadır. Tablo 3.2’de her iki yöntemin genel karşılaştırması verilmiştir.

- **Temel Yaklaşım:**

Makine Öğrenmesi: Makine öğrenmesi, verilerden desenler ve ilişkiler çıkarmak için çeşitli istatistiksel ve matematiksel algoritmaları kullanır. Öğrenme süreci genellikle insan müdahalesiyle yönlendirilir ve özellik mühendisliği gibi adımlar gerektirebilir.

Derin Öğrenme: Derin öğrenme, çok katmanlı yapay sinir ağları kullanarak karmaşık görevleri gerçekleştirmek adına tasarlanmış bir alt koldur. Derin öğrenme modelleri, veri üzerinde otomatik olarak özellik çıkarımı yapar ve genellikle daha karmaşık ve büyük veri kümeleri üzerinde etkilidir.

- **Veri Miktarı ve Boyutu:**

Makine Öğrenmesi: Makine öğrenmesi genellikle daha küçük ve yapılandırılmış veri setleri üzerinde etkilidir. Bu, genellikle elle oluşturulmuş özelliklerle beslenen gözetimli veya gözetimsiz öğrenme algoritmaları kullanılarak gerçekleştirilir.

Derin Öğrenme: Derin öğrenme, büyük miktarda veri ve yüksek boyutlu veri kümeleri üzerinde etkili olabilir. Derin öğrenme modelleri, genellikle düşük seviyeli özelliklerin otomatik olarak öğrenilmesini sağlayarak, bu büyük veri setlerinden özellikler çıkarır.

Tablo 3.2. Makine öğrenmesi ve derin öğrenmenin genel karşılaştırılması

Parametre	Makine Öğrenimi	Derin Öğrenme
Veri Bağımlılığı	Daha küçük verilerle çalışır, ancak daha iyi performans için daha fazlasına ihtiyaç duyar.	İyi performans için büyük miktarda veriye ihtiyaç duyar.
Yürütme süresi	Daha hızlı eğitim, daha uzun test.	Daha uzun eğitim, daha hızlı test.
Donanım Bağımlılıkları	Düşük kaliteli makinelerde çalışır.	GPU'lar ve üst düzey makineler gerektirir.
Özellik Mühendisliği	Manuel özellik çıkarma gerekir	Verilerden üst düzey özellikleri öğrenir.
Problem çözme yaklaşımı	Sorunu alt parçalara ayırır.	Uçtan uca yaklaşımı takip eder.
Sonucun yorumlanması	Sonuçları yorumlamak kolaydır.	Sonuçları yorumlamak zordur.
Veri türü	Çoğunlukla yapılandırılmış verileri işler.	Hem yapılandırılmış hem de yapılandırılmamış verileri işler.
Uygunluk	Basitten biraz karmaşık problemlere.	Karmaşık problemlere.

- **Özellik Mühendisliği:**

Makine Öğrenmesi: Makine öğrenmesi genellikle veri öncesi işleme adımları ve özellik mühendisliği gerektirir. Bu, verilerin daha uygun hale getirilmesi için elle özelliklerin seçilmesi veya oluşturulması anlamına gelebilir.

Derin Öğrenme: Derin öğrenme, veri tabanlı özellik çıkarımı ve otomatik özellik öğrenimi yapar. Bu nedenle, genellikle veri öncesi işleme ve özellik mühendisliği gerektirmez.

- **Model Karmaşıklığı ve Yapı:**

Makine Öğrenmesi: Makine öğrenmesi modelleri genellikle daha basit ve sıgıdır. Bu, daha az veri ile eğitilir ve genellikle daha az hesaplama gücü gerektirir.

Derin Öğrenme: Derin öğrenme modelleri, daha derin katmanlara sahip yapay sinir ağları kullanarak gelişmiş yapılar inşa ederler. Bu süreç, artan veri miktarları ve hesaplama kapasitesi talep eder, fakat genellikle daha zorlu görevlerde daha üstün performans sergilerler.

3.9. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (Convolutional Neural Network-CNN), bilgisayarlı görüş ve diğer görsel işleme alanlarında devrim niteliğinde ilerlemeler sağlamıştır. Özellikle, nesne tanıma, yüz tanıma, tıbbi görüntüleme, otomatik sürüş gibi alanlarda yaygın olarak kullanılmaktadırlar. Bu modeller, büyük veri kümelerinden karmaşık görsel desenleri öğrenme yetenekleriyle dikkat çekmektedirler. CNN'ler, görsel verilerin işlenmesi için özel olarak tasarlanmış derin öğrenme modelleridir. Geleneksel yapay sinir ağlarının aksine, CNN'ler görsel verilerin yapısını göz önünde bulunduran katmanlar içerir. Bu katmanlar arasında özellikle konvolüsyon katmanları, havuzlama katmanları ve tam bağlantılı katmanlar bulunur. Konvolüsyon katmanları, görüntü üzerinde farklı filtrelerin uygulanmasıyla özellik haritalarını oluşturur. Havuzlama katmanları, özellik haritalarını özetler ve boyutunu azaltır. Tam bağlantılı katmanlar ise özellik haritalarından gelen özellikleri kullanarak sınıflandırma veya segmentasyon gibi görevleri gerçekleştirir. CNN'ler sınıflandırma ve segmentasyon amacıyla kullanılmaktadır ve ileri beslemeli yapay sinir ağlarına örnek teşkil etmektedir (Wang vd., 2020). Bu ağlar, çoklu evrişim katmanları içererek küçük ölçekli öznitelik haritaları elde edilmektedir. Öznitelik çıkarım süreci, ağın genel doğruluğu açısından kritik öneme sahiptir. Bu süreçte, zengin öznitelik haritaları elde etmek için birden fazla evrişim ve havuzlama katmanları kullanılmaktadır. Öznitelik çıkarımında tercih edilen popüler mimariler, VGGNet (Simonyan ve

Zisserman, 2014), GoogleNet (Szegedy vd., 2015), AlexNet (Krizhevsky vd., 2017), ResNet (He vd., 2016) ve YOLO (Redmon vd., 2016) olarak sıralanmaktadır.

Nesne tespiti için kullanılan algoritmalar iki ana kategoriye ayrılmaktadır: İki aşamalı ve tek aşamalı yöntemler. İki aşamalı yöntemler, sayısız öneri seçimiyle başlamakta ve önerilen bölgelerde tahmin yapmaktadır. Bu türün örnekleri arasında R-CNN (Girshick vd., 2015) ve onun varyantları yer almaktadır. Tek aşamalı yöntemler ise, aday bölgelerin seçimini ortadan kaldırmakta ve bu sayede daha hızlı olmaktadır; ancak, genellikle iki aşamalı yöntemlere göre daha düşük doğruluk oranına sahip olmaktadır.

3.10. Görüntü İşleme

Görüntü işleme, dijital görüntülerin analiz edilmesi ve işlenmesi için kullanılan bir teknolojidir. Bu teknoloji, görüntülerin iyileştirilmesi, bilgi çıkarılması, desen tanıma, görüntü sınıflandırılması ve görüntüler üzerinden özellik çıkarımı gibi bir dizi işlemi kapsar. Görüntü işleme, çeşitli disiplinlerde uygulama alanları bulmaktadır, örneğin tıpta görüntü tabanlı tanı ve tedavi yöntemlerinde, bitkisel tarım ürünlerinde hastalık tespitinde, uzaktan algılamada yeryüzü ve atmosferik koşulların izlenmesinde, otomotiv sektöründe otonom araçların geliştirilmesinde ve güvenlik sistemlerinde yüz tanıma teknolojilerinde kullanılmaktadır.

Görüntü işleme alanında yapılan literatür taraması, derin öğrenme ve yapay zeka teknolojilerinin etkileşimine odaklanmaktadır. Özellikle, görüntü altyazılama (image captioning) üzerine yapılan çalışmalar, bu alandaki en dikkat çekici araştırmalardan biridir. Staniūtė ve Šešok'un (2019) yaptığı Sistematik Literatür İncelemesi (SLR), son yıllarda bu alandaki gelişmeleri ve zorlukları özetlemekte ve en yeni makalelerden elde edilen sonuçları sunmaktadır. Örneğin, Zhao vd. (2024) tarafından geliştirilen bir YOLOv8x-SPPCSPC-CBAM modeli, taze çay yapraklarının kalite sınıflandırılmasında kullanılmış, Fan vd. (2024) ise göğüs röntgenlerinde birden fazla anormalliği tespit etmek ve kardiyomegaliyi değerlendirmek için derin öğrenme temelli bir çerçeve geliştirmişlerdir.

Görüntü işleme teknolojileri, sağlık, eğitim, güvenlik ve birçok diğer alanda geniş uygulama olanakları sunmaktadır. Bu alanda yapılan çalışmalar genellikle derin öğrenme,

nöral ağlar ve çeşitli algoritmaların kullanımını içerir. Görüntü işleme, otomatik görüntü iyileştirme, gürültü azaltma, görüntü segmentasyonu ve nesne tanıma gibi birçok alt konuyu kapsar. Bu konular, ilgili literatürde geniş yer tutmakta ve her biri, alanın genel gelişimine katkıda bulunmaktadır.

Sonuç olarak, görüntü işleme derin öğrenme ve yapay zekanın çeşitli uygulamalarını kapsamakta ve bu teknolojilerin gelişimiyle birlikte sürekli olarak yenilenmektedir. Bu alandaki gelişmeler, akademik araştırmaların yanı sıra pratik uygulamalara da yol açmaktadır.

3.10.1. Yapay zeka ile gelişen tarımda görüntü işlemenin rolü

Görüntü işleme, özellikle yapay zeka (YZ) teknolojilerinin entegrasyonu ile tarım sektöründe önemli bir rol oynamaktadır. YZ ve görüntü işleme tekniklerinin birleşimi, bitkisel tarım ürünlerinde hastalık tespiti ve yönetimi alanında devrim yaratmaktadır. Bu teknolojiler, bitki yapraklarından hastalık belirtilerini tespit edebilir, hastalığın türünü sınıflandırabilir ve etkili tedavi yöntemlerini önermek için kullanılabilir. Örneğin, derin öğrenme tabanlı algoritmalar, bitki hastalıklarının erken aşamada tanımlanmasını sağlayarak, tarım ürünlerinin verimliliğini artırabilir ve hastalığın yayılmasını önleyebilir.

Yapay zeka, aynı zamanda, tarım alanlarının uzaktan izlenmesi ve tarımsal üretimin verimliliğinin artırılması için kullanılabilir. Uydu görüntüleri ve İnsansız Hava Araçları (İHA'lar) tarafından toplanan veriler, yapay zeka algoritmaları ile işlenerek, ekinlerin sağlık durumu, su stresi seviyeleri ve besin eksiklikleri gibi kritik bilgiler sağlayabilir. Bu bilgiler, çiftçilere ve tarım uzmanlarına, tarım faaliyetlerini daha etkin bir şekilde yönetmeleri için değerli içgörüler sunar.

Bitki hastalıkları konusunda, yapay zeka temelli görüntü işleme uygulamaları, bitkilerin yapraklarındaki renk değişiklikleri, lekelenmeler ve diğer anomali belirtilerini tespit edebilir. Bu teknoloji, bitki patolojilerini daha hızlı ve doğru bir şekilde tanımlayarak, zamanında müdahale ve tedavi sağlar. Ayrıca, bu sistemler, çiftçilere hastalığın yayılmasını önlemek için gerekli önlemleri almak üzere uyarılar gönderebilir. Bu,

özellikle büyük tarım işletmelerinde, hastalık yönetimini kolaylaştırır ve geniş alanlarda verim kayıplarını önler.

Yapay zeka tabanlı görüntü işleme teknolojileri, tarımsal verimliliği ve sürdürülebilirliği artırmak için büyük potansiyele sahiptir. Bu teknolojiler, tarım sektörünün karşılaştığı zorlukları aşmada ve küresel gıda güvenliğini sağlamada önemli bir rol oynayabilir. Bu alandaki gelişmeler, tarım sektörünün geleceğini şekillendirme potansiyeline sahiptir ve sürekli olarak yenilenen araştırmalar ve inovasyonlarla desteklenmektedir.

3.11. ResNet ve YOLO'nun Önemi

Residual Network (ResNet) ve You Only Look Once (YOLO) gibi derin öğrenme modelleri genellikle temel olarak CNN mimarilerine dayanır. Örneğin, ResNet, temelde çeşitli bloklardan oluşan bir CNN yapısıdır ve Artık Öğrenme (Residual Learning) adı verilen özel bir teknikle derin ağların eğitimini kolaylaştırır. YOLO ise nesne algılama için kullanılan bir derin öğrenme modelidir ve temelde bir CNN mimarisi üzerine inşa edilmiştir.

ResNet, Microsoft Research tarafından 2015 yılında tanıtılan derin öğrenme modelidir. ResNet'in temel özelliği, geçiş katmanlarında atlanan bağlantılar veya "skip connections" kullanarak ağın daha derin olmasını sağlamaktır. Bu, ağın daha derin olmasının getirdiği optimizasyon zorluklarını aşmaya yardımcı olurken, aynı zamanda geriye doğru yayılma sırasında kaybolan gradyanların etkisini azaltır. Bu sayede, daha derin ağlar daha iyi performans gösterirken, aşırı öğrenme ve gradyan kaybı gibi sorunlar azaltılmış olur. ResNet, "kaybolan gradyan" probleminde çözüm getiren atlamalı bağlantılar sayesinde, daha derin ağ yapıları oluşturulmasını mümkün kılmıştır (He vd., 2016). Bu durum, nesne tespiti gibi görsel görevlerde karmaşık ve ayrıntılı özelliklerin öğrenilmesine olanak tanımaktadır.

YOLO, nesne tanıma alanında önemli bir ilerleme olan "You Only Look Once" ifadesinin kısaltmasıdır. YOLO, bir resmi tek bir işlemde analiz eden ve nesnelerin sınırlayıcı kutularını ve sınıflarını doğrudan tahmin eden bir nesne algılama algoritmasıdır. Bu, diğer geleneksel nesne algılama yöntemlerine göre çok daha hızlı bir şekilde çalışmasını sağlar ve gerçek zamanlı uygulamalarda kullanılabilirliği artırır. YOLO nesne tespitindeki hız

ve doğruluk dengesini yeniden tanımlayan tek aşamalı bir algılayıcıdır. Görüntüdeki nesneler tek bir ağ geçişiyle tahmin edilerek, gerçek zamanlı uygulamalarda etkili bir seçenek haline gelmiştir (Redmon vd., 2016).

Özetle; ResNet, özellikle görüntü sınıflandırma, nesne tanıma ve segmentasyon gibi görsel görevlerde etkilidir. YOLO ise özellikle gerçek zamanlı nesne algılama ve izleme gibi uygulamalarda kullanılır. Örneğin, otomatik sürüş sistemlerinde, güvenlik kameralarında ve tıbbi görüntüleme uygulamalarında yaygın olarak kullanılırlar.

ResNet ve YOLO, farklı özelliklere sahip olmalarına rağmen, her ikisi de derin öğrenme modellerinin önemli örnekleridir. ResNet, daha doğru sınıflandırma sonuçları ve genel olarak daha yüksek performans sağlarken, YOLO daha hızlı ve gerçek zamanlı uygulamalar için daha uygundur.

- **Avantajlar:**

ResNet: Daha derin ağlarla daha iyi performans sağlar.

YOLO: Gerçek zamanlı nesne algılama için hızlı ve etkilidir.

- **Dezavantajlar:**

ResNet: Derin ağlar eğitilirken daha fazla hesaplama gücü ve veri gerektirebilir.

YOLO: Küçük nesneleri algılama konusunda diğer yöntemlere göre daha az hassas olabilir.

Bu nedenlerle, ResNet'in derinliği ve YOLO'nun hızı, bu çalışmada nesne tespiti için ideal tercihlerdir. ResNet derin ve zengin öznitelik çıkarımı sağlarken, YOLO hızlı ve etkili nesne lokalizasyonu sunmaktadır. Bu kombinasyon, doğruluk ve işlem hızı açısından dengeli bir nesne tespiti çözümü oluşturmaktadır.

3.12. ResNet Modeli ve Gelişimi


ResNet, derin öğrenme alanında devrim yaratan ve özellikle derin sinir ağlarının daha etkin bir şekilde eğitilmesini sağlayan bir yapay sinir ağı mimarisidir. "Artık öğrenme" (residual learning) fikrini temel alır. Bu, ağın çıktısına girişin bir kopyasını ekleyerek,

ağın her katmanının öğrenmesi gereken şeyin sadece giriş ve çıktı arasındaki fark, yani "artık" olduğu fikrine dayanır.

ResNet mimarisi, özellikle çok derin ağlarda karşılaşılan "kaybolan gradyan" problemine bir çözüm sunar. Bu sayede, önceden mümkün olmayan yüzlerce veya binlerce katmana sahip modeller eğitilebilir hale gelmiştir.

ResNet, "kaybolan gradyan" problemine çözüm getiren yenilikçi bir yapı sunmaktadır. Bu model, önceki modellere göre daha az karmaşıklık ve hesaplama ihtiyacı gösterirken, 152 katmana kadar derinleşebilmektedir. ResNet'in anahtar yeniliği, 'atlamalı bağlantılar' (skip connections) olarak adlandırılan bir mekanizmadır. Bu mekanizma, ağın derin katmanlarında bile gradyanın etkin bir şekilde yayılmasını sağlayarak, eğitim sürecini daha verimli hale getirmektedir. ResNet, görüntü tanıma ve işlemede geniş çapta kullanılmaktadır. ImageNet gibi büyük veri setlerinde yüksek doğruluk oranları elde ederek, görsel tanıma alanında yeni standartlar belirlemiştir. Tıbbi görüntü analizi ve otomatik araç yönlendirme gibi çeşitli alanlarda da kullanılmaktadır (He vd., 2016).


ResNet artık değerler için sonraki katmanları besleyen blokların (residual block) modele eklenmesiyle oluşmaktadır. ResNet, diğer sınıflandırma algoritmalarına göre daha üstün özellikler sunmaktadır (Kızrak, 2018). He vd.'nin çalışmalarında kullanılan 34 katmanlı model ve ResNet uygulanmış hali Şekil 3.5'te gösterilmiştir. Şekilde, 34 parametre katmanına sahip artık (residual) bir ağ ve düz (genel) bir ağın görünümeleri karşılaştırılmaktadır (He vd., 2016).



Şekil 3.5. ResNet mimarisi

ResNet, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ImageNet Large Scale Visual Recognition Challenge 2015 | ILSVRC2015) yarışmasında, ImageNet veri setinde VGG ağlarından daha derin ve daha düşük karmaşıklığa sahip 152 katmanlı residual networklerin değerlendirilmesi sonucunda %3,57 hata payı ile sınıflandırmada birinci olmuştur (Kızrak, 2018; He vd., 2016).

ResNet modeli, Şekil 3.6'da gösterilen residual bloklardan oluşmaktadır. Her katmanın çıktısı, bir sonraki katmanın çıktısıyla birleştirilerek yeniden filtreleme işlemleri yapılmıştır. Şekil 3.6'da sol tarafta ResNet34 yapı taşının (56×56 özellik haritalarında) gösterimi, sağ tarafta ise ResNet-50/101/152 için "bottleneck" yapı taşının gösterimi yer almaktadır. Bilgisayar görüntü analizi alanında yeni modeller geliştiren açık kaynak olarak, CNN tabanlı ResNet50 mimarisi 50 katmanın inşasında beş evrişimsel blok kullanmıştır. Bu bloklar arasında, 1×1 evrişim katmanı ile giriş görüntüleri daha düşük boyuta indirgenmiş ve 3×3 evrişimler katmanı ile daha yüksek boyutlarda filtreleme işlemi gerçekleştirilmiştir.



Şekil 3.6. Residual fonksiyonu görünümü

3.12.1. ResNet modelleri

ResNet modelin farklı versiyonları, özellikle görsel tanıma görevlerinde yaygın olarak kullanılmaktadır. ResNet50, ResNet101 ve ResNet152, bu modelin en popüler varyasyonları arasında yer almakta ve her biri farklı derinlikte katmanlara sahiptir.

- **ResNet50**

ResNet50, 50 katmandan oluşan bir yapıya sahip olup, görsel tanıma, nesne algılama ve sınıflandırma gibi alanlarda kullanılmaktadır. Daha az katman içermesine rağmen etkileyici bir doğruluk oranı sunan bu model, kaynak sınırlı durumlar için idealdir.

- **ResNet101**

ResNet101, 101 katman içeren ve daha derin bir yapıya sahip olan bir modeldir. Bu ekstra derinlik, modelin karmaşık veri setleri üzerinde daha iyi performans göstermesini sağlamaktadır. ResNet101, detaylı görsel özelliklerin algılanması gereken durumlarda tercih edilmektedir.

- **ResNet152**

ResNet152, 152 katmana sahip olup, ResNet serisinin en derin modelidir. Özellikle büyük ve karmaşık veri kümelerinde yüksek doğruluk oranları elde etmek için kullanılan bu model, karmaşık görsel örüntüleri algılama yeteneğini artırmaktadır.

ResNet50, ResNet101 ve ResNet152 modelleri arasındaki temel fark, katman sayıları ve buna bağlı hesaplama gereksinimleridir. ResNet50, daha hızlı eğitim süreleri ve daha az kaynak gereksinimi sunarken, ResNet152, daha karmaşık görevler için daha uygun bir seçenek olabilmektedir. Bu modellerin seçimi, kullanım durumuna ve mevcut kaynaklara bağlı olarak değişmektedir. Şekil 3.7’de ResNet’in çeşitli derinliklerdeki versiyonları (18, 34, 50, 101, 152 katman) için katman yapıları ve bu yapıların FLOPs (Floating Point Operations Per Second) değerleri verilmiştir. FLOPs, modelin karmaşıklığını ve hesaplama yükünü ölçen bir metriktir.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
conv2_x	56×56	3×3 max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 3.7. ResNet’in çeşitli derinliklerdeki versiyonları

conv1: Bu, ilk evrişim katmanıdır ve genellikle görüntüdeki düşük seviyeli özellikleri (kenarlar, renkler, doku vb.) çıkarmak için kullanılır.

conv2_x - conv5_x: Bu katmanlar, mimarinin esasını oluşturan ve "residual blocks" olarak adlandırılan yapıları içerir. Her blok, girişin bir kopyasını çıktıyla toplayarak gradyanların derin katmanlara ulaşmasını kolaylaştırır, bu da modelin daha derin katmanlarda bile eğitilmesini sağlar (Bkz. Şekil 3.6).

18-layer ile 152-layer arası: Her sütun, ResNet'in belirli bir derinlikteki versiyonunu temsil eder. Katman sayısı arttıkça, modelin öğrenebileceği özelliklerin karmaşıklığı ve çeşitliliği artar, ancak bu aynı zamanda daha fazla hesaplama gücü ve eğitim süresi gerektirir.

FLOPs: Her modelin hesaplama yükünü gösterir. Katman sayısı arttıkça FLOPs değeri de artar, bu da doğrudan modelin ne kadar hesaplama kaynağı gerektireceğini gösterir.

Sonuç olarak Şekil 3.7'de ResNet mimarisinin çeşitli yapılarının ve her birinin hesaplama maliyetlerinin bir özeti sunulmuştur. Daha derin modeller, daha iyi performans potansiyeli sunarken, aynı zamanda daha fazla hesaplama gücü gerektirir ve eğitim süreleri uzar. Bu nedenle, bir model seçimi yapılırken, kullanılacak donanım kaynakları ve eğitim süresi gibi pratik kısıtlamalar dikkate alınmalıdır.

ResNet, derin ağ yapılarını eğitmeyi daha pratik hale getirerek, derin öğrenmenin uygulanabilirliğini artırmıştır. Modelin güçlü yönleri, eğitim süresinin kısalması ve daha az hesaplama gereksinimi olarak öne çıkmaktadır. Ancak, modelin bazı sınırlılıkları da bulunmaktadır. Örneğin, çok derin ağlar hala zorlu hesaplama gereksinimleri sunmakta ve bazı durumlarda aşırı uyuma (overfitting) eğilimi göstermektedir.

3.12.2. Tarımda ResNet modelinin kullanım alanları

ResNet modelinin tarım sektöründeki uygulamaları, özellikle görüntü işleme ve yapay zeka alanında önemli gelişmelere yol açmıştır. He vd. (2016) tarafından geliştirilen ResNet modeli, derin öğrenme konusunda devrim yaratarak, görüntü tanıma ve sınıflandırmada yeni standartlar belirlemiştir. Tarımda ResNet modelinin uygulamaları ve kullanım alanlarına örnekler aşağıdaki gibi sıralanabilir:

Hastalık Tespiti ve Sınıflandırması: ResNet, bitki hastalıklarını tespit etme ve sınıflandırma konusunda yüksek doğruluk sağlar (Liu vd., 2018). Görüntü tabanlı hastalık

tanımlama, erken müdahale ve tedavi seçeneklerinin belirlenmesinde kritik öneme sahiptir.

Verim Tahmini: Tarım alanlarının verimliliği, ResNet modeli kullanılarak tahmin edilebilir. Bu, bitki büyüme oranları ve sağlık durumları hakkında önemli bilgiler sağlar (Patrício ve Rieder, 2018).

Bitki Türü ve Olgunluk Seviyesi Tanıma: ResNet, farklı bitki türlerini ve olgunluk seviyelerini belirlemede kullanılır, bu da hasat zamanlamasının optimize edilmesine yardımcı olur (Kamilaris ve Prenafeta-Boldú, 2018).

ResNet Modelinin Avantajları:

- **Derin Öğrenme Kapasitesi:** ResNet, daha derin ağ yapıları ile karmaşık görsel desenleri tanıyabilir.
- **Eğitim Kolaylığı:** Kalıntı öğrenme yaklaşımı, daha derin ağların eğitilmesini kolaylaştırır.
- **Uygulama Çeşitliliği:** ResNet, tarımın çeşitli yönlerine uyarlanabilir, geniş bir uygulama yelpazesi sunar (Kamilaris ve Prenafeta-Boldú, 2018).

Bu teknolojilerin gelişimi, tarım sektörünün karşılaştığı zorlukları aşmada ve küresel gıda güvenliğini sağlamada önemli bir rol oynayabilir. ResNet modelinin tarımdaki bu uygulamaları, tarımsal üretimin verimliliğini artırmak, kaynak kullanımını optimize etmek ve sürdürülebilir tarım uygulamalarını desteklemek açısından çok büyük potansiyel taşımaktadır.

3.13. YOLO Modeli ve Gelişimi

YOLO (You Only Look Once – Sadece Bir Kez Bak), 2015 yılında Joseph Redmon ve arkadaşları tarafından geliştirilen bir nesne tanıma algoritmasıdır. Bu algoritma, görüntü içindeki nesneleri tek bir bakışta tanıyabilme özelliğine sahiptir, bu da önceki yöntemlere göre daha hızlı ve verimli olmasını sağlar. YOLO, bir görüntüyü birden fazla bölgeye ayırır ve her bölgedeki nesneleri eş zamanlı olarak tahmin eder. Bu işlem, tek bir sinir ağı kullanılarak gerçekleştirilir ve her bölge için nesne sınıflandırması ve konumlandırılması yapılır. Geleneksel nesne tanıma yöntemleri olan R-CNN ve SSD ile karşılaştırıldığında,

YOLO'nun çok daha hızlı olduđu gör÷lmektedir. Ancak, bu hız bazen doğruluk oranında azalmaya neden olabilir. YOLO, tüm görüntü üzerinde eş zamanlı tahminler yaparak, R-CNN ve SSD'nin nesneleri ayrı ayrı analiz etme yöntemine üstünlük sağlar (Redmon vd., 2016).

YOLO, derin evrişimli sinir ağıları temeline dayanmaktadır. Görüntüyü bölümlere ayırarak her bölüm için sınıflandırma ve sınır kutularını tahmin eder. YOLO'nun temelini oluşturan yapay sinir ağıları, büyük veri setlerinden öğrenme yeteneğine sahip olup, karmaşık görsel verileri işleyebilir (LeCun vd., 2015). YOLO'nun çoğunlukla kullanıldığı alanlar aşağıda verilmiştir:

Güvenlik Sistemleri: YOLO, gerçek zamanlı video izleme ve güvenlik sistemlerinde hızlı ve doğru nesne tanıma yeteneği ile etkili bir şekilde kullanılmaktadır (Shinde vd., 2018)

Otomatik Sürüş Teknolojileri: Otomatik sürüş sistemlerinde yaya, araç ve diğer engellerin tanınmasında YOLO sıklıkla kullanılmaktadır, bu da sürüş güvenliğini artıran ve karar verme süreçlerini hızlandıran bir faktördür.

Endüstriyel ve Tıbbi Görüntüleme: Endüstriyel tespit ve tıbbi görüntüleme alanlarında da YOLO, özellikle tıbbi görüntülerdeki anormalliklerin tespiti için etkili bir araç olarak kullanılmaktadır.

3.13.1. YOLO modelleri

YOLO'nun farklı versiyonları, algoritmanın farklı iyileştirmeler ve özelliklerle geliştirilmiş sürümlerini içerir.

YOLOv1: YOLO'nun ilk sürümü ve bir görüntüyü tek bir konvolüsyon ağı geçişinde analiz eden orijinal YOLO modelidir. Bu sürüm, gerçek zamanlı nesne algılama konusunda çığır açan hız ve doğruluk sağlamıştır. Ancak, küçük nesnelerin algılanması ve sınırlı bir sınıf tahmini doğruluğu gibi bazı zorluklar vardı.

YOLOv2 (YOLO9000): YOLOv2, orijinal YOLO modelinin iyileştirilmiş bir versiyonudur. Bu sürüm, daha fazla sınıfı tanımak için daha geniş bir sınıf seti ve daha iyi bir algılama performansı sunar. Ayrıca, ilk versiyona göre küçük nesnelerin

algılanması ve doğruluk konusunda iyileştirmeler sağlanmıştır. Darknet-19 adı verilen, 19 evrişimli katmana sahip ve nesne takibi için ek olarak 11 özel katman eklenmiş derin ağ yapısı kullanılmaktadır.

YOLOv3: YOLO algoritmasının daha fazla ölçeklenebilirlik ve doğruluk için geliştirilmiş bir versiyonudur. Bu sürüm, daha derin bir ağ mimarisi kullanır ve özellikle küçük nesnelerin algılanması konusunda daha başarılıdır. Ayrıca, çoklu ölçekli özellik haritaları kullanarak nesne algılama performansını artırır. YOLOv3, kalıntı blokları (residual blocks), atlama bağlantıları (skip connection) ve örnekleme artırma (upsampling) gibi yeni özellikleri ile donatılmıştır ki bu yenilikler YOLOv2'de mevcut değildir. YOLOv3, Darknet-53 adı verilen ve toplamda 53 evrişimsel katmandan oluşan bir mimari üzerine kurulmuştur. Nesne tespiti görevlerinde, bu 53 katmanın üstüne eklenen 53 katman ile birlikte toplam 106 evrişim katmanı kullanılır. YOLOv3'ün YOLOv2'ye göre daha fazla katman içermesi, işlem süresini artırır ve bu da onu önceki versiyona göre daha yavaş hale getirir.


YOLOv4: YOLO algoritmasının daha fazla hız, doğruluk ve ölçeklenebilirlik için optimize edilmiş bir versiyonudur. Bu sürüm, çeşitli teknik iyileştirmeler ve derin öğrenme tekniklerinin kullanımıyla daha iyi bir performans sağlar. Ayrıca, önceki versiyonlara göre daha hızlı ve daha doğru sonuçlar elde etmeyi hedefler. YOLOv4, önceki sürümlere göre hız ve doğrulukta iyileştirmeler sağlamıştır. YOLOv4'ün yayımlanmasından kısa bir süre sonra, YOLOv5 ortaya çıkmıştır. YOLOv5, daha önceki sürümlerde kullanılan Darknet framework'ün aksine PyTorch tabanlıdır. YOLOv5, hız konusunda YOLOv4'e göre avantaj sağlarken, doğruluk açısından her iki model de benzer seviyelerde performans gösteriyor olabilir. Bu değişim, YOLO algoritmalarının sürekli olarak nasıl geliştirildiğini ve adaptasyonunun ne kadar hızlı olabileceğini göstermektedir.

YOLOv5s: 2020 yılında tanıtılmış ve 'v5s' (small) modeli olarak adlandırılan, YOLOv5 serisinin hafif ve hızlı versiyonudur. Hız ve verimlilik açısından optimize edilmiş olan bu model, gerçek zamanlı uygulamalar için uygun olarak geliştirilmiştir. YOLOv5 serisinin en hızlı modeli olmasının yanı sıra düşük donanım gereksinimleri ile de ön plana çıkar. Çoklu ölçekli tahminler ve çapraz bölge katmanları gibi gelişmiş özelliklere sahip olan

YOLOv5s, daha az parametre içerdiğinden dolayı hızlı ve hafif bir yapı sergiler; ancak, doğruluk açısından bazı sınırlamaları bulunabilir.

YOLOv7: YOLO ailesinin daha yeni bir üyesi olarak geliştirilmiş ve gelişmiş doğruluk ile hız özellikleri sunan bir modeldir. Önceki YOLO modellerine kıyasla daha karmaşık bir yapıya sahip olan YOLOv7, nesne tanıma performansını artıran daha derin ve geniş bir ağ yapısına sahiptir. Nesne tanıma konusunda daha hassas ve çeşitli senaryolarda iyileştirilmiş performans sergileyen YOLOv7, gelişmiş kayıp fonksiyonları ve optimizasyon teknikleri kullanır.

YOLOv8: YOLO serisinin en yeni sürümlerinden biri olarak tanımlanır ve gelişmiş algoritmik iyileştirmelerle donatılmıştır. Hem hız hem de doğruluk açısından önemli iyileştirmeler sunan YOLOv8, önceki versiyonlara kıyasla daha ileri özellik çıkarma ve sınıflandırma kabiliyetlerine sahiptir. Gelişmiş yapay zeka algoritmaları sayesinde, daha karmaşık ve çeşitli görüntü veri setlerinde etkin performans sergileyebilir. Yüksek çözünürlüklü görüntü işlemede daha iyi sonuçlar sunması beklenen YOLOv8, geniş bir uygulama yelpazesine hitap etmektedir. YOLO sürümlerinin zamana bağlı olarak ortaya çıkışları Şekil 3.8’de görülmektedir (Terven vd., 2023).




Şekil 3.8. Yolo sürümlerinin zaman çizelgesi


Şekil 3.9'deki açıklamaya göre Roboflow (2024), YOLOv8'den önceki modeller, nesne algılama işleminde başlangıç noktası olarak demirleme kutularını (anchor boxes) kullanırken, YOLOv8, demirleme kutusu içermeyen (anchor-free) bir modeldir. Bu durum, modelin bilinen bir demirleme kutusunun ofsetinden ziyade doğrudan bir nesnenin merkezini tahmin ettiği anlamına gelmektedir. Bu, önceki modellerdeki demirleme kutularıyla ilişkili karmaşıklığı azaltır ve modelin doğrudan gerçek nesne

merkezlerine odaklanmasını sağlar, böylece algılama işlemi daha doğrudan ve etkin hale gelir.

Şekil 3.10'da Roboflow (2024) Çapasız tespit (Anchor free detection), nesne algılama modellerinde, aday tespit kutularının sayısını azaltarak çıkarım işlemini basitleştirir. Bu azalma, çıkarım sonrası adımlardan biri olan ve aday tespitler arasından en uygun olanları seçmeye yarayan Maksimum Olmayan Bastırma (Non-Maximum Suppression, NMS) işleminin hızlanmasına katkıda bulunur. NMS, birden fazla kutu arasında gerçek nesneyi en iyi temsil eden kutuyu seçerken, alakasız veya gereksiz kutuları eleyerek modelin tespit performansını iyileştirir. Anchor free yaklaşımın bu avantajı, modelin genel performansını ve hızını artırarak, gerçek zamanlı uygulamalarda nesne tespiti yapma yeteneğini geliştirir.




Şekil 3.9. Yolo'da bağlantı kutusunun görselleştirilmesi



Şekil 3.10. Yolo v5'in algılama başlığı

Şekil 3.11’de Roboflow (2024) çeşitli işlemler sırasıyla gerçekleştirilerek girdi verileri nihai bir çıktıya dönüştürülür. İşlemler aşağıda verilen adımları içermektedir:



Şekil 3.11. Yolo v8’in algılama başlığı

Concat: İki veya daha fazla tensörün birleştirilmesi.

Split: Bir tensörün belirli eksenler boyunca bölünmesi.

Reshape: Tensörün yeniden şekillendirilmesi, boyutlarının değiştirilmesi.

Transpose: Tensörün eksenlerinin yer değiştirilmesi.

Softmax: Sınıflandırma görevleri için kullanılan bir normalleştirme işlemi.

Conv (Evrişim): Derin öğrenme modellerinde yaygın bir özellik çıkarım işlemi.

Sub (Çıkartma) ve Add (Toplama): Tensörler arasında eleman bazında çıkarma ve toplama işlemleri.


Div (Bölme): Bir tensörün tüm elemanlarının belirli bir değere bölünmesi.

Mul (Çarpma): Bir tensörün tüm elemanlarının belirli bir değerle çarpılması.

Sigmoid: Tensörün her bir elemanını 0 ile 1 arasında bir değere sıkıştıran bir aktivasyon fonksiyonu.

İşlem sırasında, belirli ara işlemler tensörler üzerinde yapıldıktan sonra, bu tensörler tekrar birleştirilir ve son aktivasyon fonksiyonu olan sigmoid uygulanarak çıktı tensörü elde edilir. Bu çıktı tensörü, genellikle modelin tahminlerini veya özelliklerini temsil eder ve bir sonraki aşama veya modelin nihai çıktısına yönlendirilir.

Şekil 3.12’de YOLOv8’in önceki versiyonlarla karşılaştırılması gösterilmiştir (Jocher vd., 2023).



Şekil 3.12. Yolo-v8'in önceki versiyonlarla karşılaştırılması

YOLO Modellerinin COCO Veri Seti Performans Analizi

Grafikler, YOLO modellerinin COCO (Common Objects in Context - Bağlam İçindeki Ortak Nesneler) veri seti üzerindeki performansını görselleştirmektedir. COCO veri seti, geniş bir nesne kategorisi yelpazesindeki görüntüleri içerir. mAP (mean Average Precision), bir modelin tahmin doğruluğunu ölçen bir metriktir ve mAP@.5:.95, modelin tahmin kesinliğini ve güvenilirliğini farklı IoU (Intersection over Union) eşiklerinde değerlendirir.

YOLO modelinin çeşitli versiyonları vardır ve her biri farklı boyutlarda ve kapasitelerde modeller sunar. "n", "s", "m", "l", "x" gibi harfler, modelin boyutunu ve kapasitesini ifade

eder: **n** (nano): En hafif modeldir, genellikle kaynak kısıtlı cihazlarda kullanım için tasarlanmıştır. **s** (small): Nano modelden biraz daha büyük ve doğru olan ancak hala hafif bir modeldir. **m** (medium): Orta boyutta bir modeldir ve daha yüksek doğruluk sağlar ancak hesaplama maliyeti de artar. **l** (large): Büyük boyutta bir modeldir ve daha yüksek doğruluk için tasarlanmıştır. Ancak, daha fazla hesaplama gücü gerektirir. **x** (extra large): En büyük ve en doğru modeldir, ancak en fazla hesaplama maliyetine sahiptir. Büyük ölçekli sistemlerde ve yüksek doğruluk gerektiren uygulamalarda kullanılır. Bu harfler, YOLO modelinin farklı versiyonlarının performans ve kaynak gereksinimleri arasındaki dengeyi göstermektedir.


Sol Grafik: Model Boyutu ile Performans İlişkisi: X eksenini, modelin parametre sayısını (milyonlarca) ve dolayısıyla karmaşıklığını ve eğitim için gereken hesaplama gücünü yansıtmaktadır. Y eksenini, COCO veri setindeki mAP@.5:.95 performansını göstermekte olup, yüksek değerler modelin nesneleri doğru bir şekilde tespit etme yeteneğinin göstergesidir. Grafik, parametre sayısının artışı ile performansın da arttığını; ancak, bir noktadan sonra performanstaki artışın azaldığını, yani parametre artışının performansa doğrusal olmadığını göstermektedir.

Sağ Grafik: Gecikme Süresi ile Performans İlişkisi: X eksenini, modelin nesne tespiti ne kadar hızlı gerçekleştirdiğini gösteren gecikme süresini (milisaniye) ifade eder. Y eksenini ise mAP@.5:.95 performans metriğini kullanır. Gecikme süresinin azalması ile (modelin hızlanması ile) performansın genel olarak azaldığı görülmektedir. Ancak, YOLOv8 modeli hem daha hızlı hem de yüksek performans sunarak diğer versiyonlardan ayrılmaktadır. Bu durum, YOLOv8'in hızlı ve doğru tahminler yapabilen verimli bir model olduğunu göstermektedir.

Analiz edilen grafikler, YOLO modellerinin boyut, hız ve performans açısından sunduğu dengeyi göstermektedir. YOLOv8, az sayıda parametre ile yüksek performans sunmakta ve düşük gecikme süresi ile öne çıkmaktadır. Bu özellikler, özellikle gerçek zamanlı uygulamalar için kritik önem taşımakta, çünkü bu tür uygulamalar hem yüksek doğruluk hem de hız gerektirmektedir.

Şekil 3.13'de YOLOv8 Mimarisi, GitHub kullanıcısı Range King tarafından yapılan görselleştirme (RangeKing, 2024) YOLOv8 nesne tespit algoritmasının mimarisini

göstermektedir. YOLO, gerçek zamanlı nesne tespiti için tasarlanmış popüler bir derin öğrenme algoritmasıdır. Şekilde algoritmanın üç ana bölümü ve bunların alt bileşenleri gösterilmektedir: Backbone, Head ve Details.



Şekil 3.13. Yolo v8 mimarisi

Backbone: Modelin temelini oluşturan ve girdi resminden öznetelikler (features) çıkarmak için kullanılan bölümdür. Bu kısım, çeşitli katmanlardan (P1'den P5'e) oluşur ve her biri farklı boyuttaki öznetelik haritalarını işler.

Head: Backbone tarafından çıkarılan özneteliklerin nesne tespiti için kullanıldığı bölümdür. Nesne sınıflarını ve sınırlayıcı kutuları (bounding boxes) tahmin etmek için kullanılır.

Details: Mimarinin spesifik bileşenlerinin detaylarını gösteren bölümdür. Burada, her bir bileşenin evrişim katmanları (Conv), sınıflandırma katmanları (Cls.), sınırlayıcı kutu tahmin katmanları (Bbox.) ve kayıp fonksiyonları (Loss)) yapılandırılmasını ve işlevlerini anlamak için gerekli parametreler ve yapılandırmalar detaylandırılmıştır.

Mimari aynı zamanda bölümlerin nasıl birbirine bağlandığını, bilginin nasıl ilerlediğini ve nihai tespitlerin nasıl yapıldığını görsel olarak açıklamaktadır. Bir öge, örneğin bir evrişim katmanı, başka bir ögeyle nasıl etkileşime girerse, bu etkileşim oklar ve birleştirme (concat) gibi işlemlerle gösterilir. Görselin sağ üst kısmında, algılama işleminin her aşamasında kullanılan kayıp fonksiyonlarının türleri ve sonuçların nasıl değerlendirildiğini gösteren bir kayıp şeması (Loss) bulunur. Son olarak, resmin en altında yer alan "Details" bölümünde, modelin farklı yapılandırmalarının ve parametrelerinin bir listesi yer almakta, bu da farklı derinliklerde, genişliklerde ve girdi çözünürlüklerinde modelin nasıl performans gösterebileceğine dair bilgiler sunmaktadır.

3.13.2. Tarımda YOLO modelinin kullanım alanları ve uygulamaları

Tarım sektöründe, YOLO'nun uygulamaları ve kullanım alanları oldukça geniş ve etkilidir. Bu model, tarımsal faaliyetlerde verimliliği artırmak, hastalık ve zararlı tespiti yapmak ve tarımsal süreçleri otomatize etmek için kullanılabilir. Şekil 3.14'teki görsele göre, YOLO algoritmasının anahtar bazı uygulama alanları arasında aşağıdaki başlıklar göze çarpmaktadır:

Hastalık ve Zararlı Tespiti: YOLO, bitki yaprakları üzerinde hastalık belirtileri veya zararlı böcek tespiti yapmak için kullanılabilir. Model, tarla görüntülerini analiz ederek hastalıklı veya zarar görmüş bitkileri hızlı bir şekilde tespit edebilir. Bu, hastalıkların ve zararlıların yayılmasını önlemek için erken müdahale imkânı sağlar.


Bitki Tanımlama ve Sınıflandırma: Çeşitli bitki türlerini ve çeşitlerini tanımlamak için YOLO kullanılabilir. Bu, tarımsal araştırmalarda ve çeşitli bitkilerin yönetiminde önemli bir rol oynar.

Meyve ve Sebze Hasadı: YOLO, olgun meyve ve sebzelerin tespiti ve sınıflandırılması için kullanılabilir, böylece hasat süreci otomatize edilebilir. Model, meyve ve sebzelerin

boyutunu, olgunluk derecesini ve kalitesini belirleyerek hasat için en uygun zamanı tespit edebilir.

Tarla Analizi ve Verim Tahmini: Tarlaların havadan çekilen görüntülerini analiz ederek, bitki örtüsü, verimlilik ve bitki sağlığı hakkında bilgiler sağlamak için YOLO'dan yararlanılabilir. Bu, verim tahminlerinde ve tarımsal planlamada kullanılabilir.

Otomatik Sulama ve Gübreleme Sistemleri: Bitkilerin sağlık durumunu ve ihtiyaçlarını belirlemek için kullanılan YOLO, daha etkili sulama ve gübreleme stratejileri geliştirmede yardımcı olabilir.



Şekil 3.14. Yolo'nun ana uygulamalarının bibliyometrik ağ görselleştirilmesi

Bu uygulamalar, tarımda verimliliği artırmak, maliyetleri azaltmak ve sürdürülebilir tarım uygulamalarını desteklemek için YOLO modelinin nasıl etkin bir şekilde kullanılabileceğini göstermektedir. YOLO'nun hızı ve doğruluğu, tarımsal faaliyetlerde önemli bir avantaj sağlayarak, bu alanda teknolojinin giderek artan bir rol oynamasına katkıda bulunur. YOLO ile oluşturulan ana uygulamalarının bibliyometrik ağ görselleştirmesi şekilde gösterilmiştir. Bibliyometrik ağ görselleştirmeleri, genellikle akademik yayınları ve anahtar terimleri inceleyerek bir araştırma alanındaki eğilimleri ve

ilişkileri analiz etmek için kullanılır. Bu tür görselleştirmeler, bir alandaki en önemli konuları ve bu konuların birbirleriyle nasıl etkileşime girdiğini anlamak için yararlıdır. Terven vd. (2023) Şekil 3.14'teki görselleştirme, yolo algoritmasının uygulandığı araştırma konuları ve onlarla ilişkili alt konular arasındaki ilişkileri göstermektedir.

Autonomous Vehicles: YOLO algoritması, otonom araçlarda çevreyi algılamak ve trafik işaretlerini, yayaları, diğer araçları ve çeşitli nesneleri tanımak için kullanılabilir.

Agriculture: Tarım sektöründe, bitki hastalıklarının tespiti ve hasat edilecek ürünlerin tanımlanması gibi işlemler için YOLO uygulanabilir.

Security Systems: Güvenlik sistemlerinde insanlar, yüzler veya diğer güvenlikle ilgili nesnelerin tanımlanması için YOLO'dan faydalanılmaktadır.

Remote Sensing: Uzaktan algılama uygulamaları, özellikle insansız hava araçları (İHA) üzerinden, YOLO'yu kullanarak yer yüzeyini ve çeşitli nesneleri tanımak için kullanılabilir.

Şekildeki farklı renkler ve hatlar, konular arasındaki ilişkilerin yoğunluğunu ve doğasını ifade ediyor. Örneğin, bazı alanlar diğerlerine göre daha fazla bağlantıya sahip olabilir, bu da o konunun YOLO algoritmasıyla ilgili çalışmalarda daha merkezi bir rol oynadığını gösterir.

4. MATERYAL ve YÖNTEM

Bu çalışmada, mısır ve buğdayın yaprak hastalıkları üzerine yoğunlaşmıştır. Mısır için, mısır yapraklarındaki adi pas, gri yaprak lekesi ve yaprak yanıklığı hastalıklarının yanı sıra sağlıklı yaprakların tespiti için derin öğrenme yaklaşımı benimsenmektedir. Bu amaçla, Residual Network (ResNet) modeli, Kaggle üzerinden elde edilen 4.188 mısır yaprağı görüntüsü içeren veri seti üzerinde uygulanmıştır. Çalışma, Google Collaboratory "Colab" ortamında ResNet50, ResNet101 ve ResNet152 modelleri ile yürütülmüştür. Modeller, mısır yaprak hastalıklarını tanımlamada gelişmiş görsel analiz teknikleri kullanarak yüksek doğruluk oranlarına ulaşmayı hedeflemektedir.


Aynı zamanda, buğday için, buğday yaprak hastalıklarının sınıflandırılması üzerine yapılan bu çalışmada, Mendeley Data'dan elde edilen ve roboflow platformunda etiketlenen 407 adet buğday yaprağı görüntüsü, veri artırma teknikleri kullanılarak 977 adete çıkarılmıştır. Veri artırma işlemi, veri setinin çeşitliliğini ve genişliğini artırmış ve modelin kapsamlı öğrenmesine olanak tanımıştır. Genişletilmiş veri seti, buğday septorya yaprak lekesi, çizgi pası ve normal yaprakları kapsamaktadır. Çalışmada, CNN tabanlı Ultralytics – YOLO modelleri kullanılmıştır. Colab ortamında gerçekleştirilen analizler, YOLO-v5s ve YOLO-v8 modelleri üzerinden yürütülmüştür.

ResNet ve YOLO modellerinin performans karşılaştırmaları yapılmıştır. Bu karşılaştırmalar, mısır ve buğday yaprak hastalıklarını sınıflandırmada en etkili yöntemin belirlenmesi ve model performanslarının literatürde benzer veri setleri üzerinde yapılan çalışmalarla kıyaslanması amacıyla taşımaktadır.

4.1. Veri Seti

Bu çalışma, mısır yaprak hastalıklarının tespiti ve sınıflandırılması için Kaggle platformundan alınan "Corn or Maize Leaf Disease Dataset" adlı veri setini kullanmaktadır (Kaggle, 2023). Bu veri seti, mısır yaprağı hastalıklarının tespiti konusunda derin öğrenme tekniklerinin uygulanmasına temel oluşturmaktadır. Bu veri seti, popüler PlantVillage ve PlantDoc veri setleri kullanılarak yapılmıştır. Veri setinin oluşturulması sırasında yararlı olmadığı düşünülen bazı görseller çıkarılmıştır. Çalışmada incelenen veri seti, mısır yapraklarında görülen mısır adi pası (common rust), gri yaprak

lekesi (gray leaf spot) ve yaprak yanıklığı (blight) olan üç farklı hastalık ve sağlıklı (normal) yaprakları kapsamaktadır. Şekil 4.1'de bu dört farklı sınıfa ait örnek görüntüler verilmiştir. Veri setindeki tüm görüntüler “.jpg” formatındadır.



Şekil 4. 1. (a) mısır adi pası (b) gri yaprak lekesi (c) yaprak yanıklığı (d) normal verisetindeki mısır sınıfına ait örnek görüntüler

Veri seti, toplam 4.188 görüntüden oluşup, mısır adi pası için 1306, gri yaprak lekesi için 574, yaprak yanıklığı için 1146 ve sağlıklı yapraklar için 1162 görüntü içerir. Bu veriler ve sınıflandırmalar, detaylı olarak Türkçe, İngilizce ve Latince isimleri ile birlikte verilmiştir. Tablolarda her bir hastalığın farklı dillerdeki adlandırılmasının yanı sıra, araştırma için kullanılan görüntü sayıları da detaylı bir şekilde Tablo 4.1'de yer almaktadır.

Ayrıca mısır verisetinin oluşturulmasında bu alanda önemli diğer çalışmalar olan Singh vd. (2020) tarafından sunulan ve Geetharamani ve Pandian' ın (2019) çalışmaları da dikkate alınmış ve veri seti oluşturulmuştur. Bu kaynaklar, bitki yaprak hastalıklarının tespiti konusunda derin öğrenme modellerinin kullanımı hakkında bilgiler sunmaktadır.

Tablo 4.1. Mısır verisetinin ayrıntıları


Türkçe	İngilizce	Latince	Görüntü Sayısı
Mısır Adi Pası	Common rust	Puccinia sorghi Schw.	1.306
Gri yaprak lekesi	Gray Leaf Spot	Cercospora spp.	574
Yaprak Yanıklığı	Blight	Helminthosporium Maydis	1.146
Normal (Sağlıklı)	Healthy	-	1.162
Veri Setindeki Toplam Görüntü			4.188

Bu çalışmada incelenen diğer veri seti de Buğday yaprak hastalıkları için "*Wheat Leaf Dataset*", Mendeley Data platformu üzerinden temin edilmiştir (Mendeley, 2024). Mendeley Data platformu, araştırmacılara veri depolama ve paylaşımı konusunda kolaylık sağlamaktadır. Buğday yaprak hastalıklarının tespiti ve sınıflandırılması için kullanılan bu veri seti, tarımsal hastalık tanımlama süreçlerinde derin öğrenme tekniklerinin etkinliğini artırmayı amaçlamaktadır. Veri toplamanın yeri Etiyopya'daki Holeta buğday çiftliğindedir ve kontrolsüz bir ortamda gerçek bir buğday çiftliğinde toplanmıştır. Ayrıca bitki patoloğlarının yardımıyla üç sınıfa ayrılmıştır: Sınıflar Stripe Rust, Septoria ve Healthy'tır. Kullanılan kamera Canon EOS 5D Mark III olup, yaprağın detayını gösterebilen yüksek çözünürlüklü bir dijital kameradır. 102 adet sağlıklı buğday yaprağı, 208 adet çizgili pastan etkilenmiş buğday yaprağı ve 97 adet septoriadan etkilenmiş yaprak içermektedir. Veri setindeki tüm görüntüler “.jpg” formatındadır.

Buğday yaprak hastalıkları için kullanılan veri setine ait örnek görüntüler Şekil 4.2’de verilmiştir. Verisetinin görüntülerin alındığı Etiyopya, çeşitlilik açısından zengin tarım kaynaklarına sahip olup, buğday ülkenin temel mahsulleri arasında yer almaktadır. Ancak, buğday üretimi, çeşitli patojenler tarafından tehdit edilmektedir. Getachew ve Hawi (2021) tarafından yürütülen çalışmada, Stripe Rust (Çizgili Pas) ve Septoria gibi iki önemli buğday hastalığının tespiti için özel bir buğday yaprağı görüntü seti kullanılmıştır.

Buğday veri setinde, 102 adet sağlıklı buğday yaprağı, 208 adet Çizgili Pas ve 97 adet Septoria buğday yaprağı görüntüsünü kapsamaktadır. Bu çalışmada incelenen buğday yaprağı hastalıkları ise Türkçe, İngilizce ve Latince isimleri ile birlikte verilmiştir. Tablo

4.2'de her bir hastalığın farklı dillerdeki adlandırılmasının yanı sıra, araştırma için kullanılan görüntü sayıları da detaylı bir şekilde yer almaktadır.



Şekil 4. 2. (a) septorya yaprak lekesi (b) çizgi pası-sarı pas (c) normal verisetindeki buğday sınıfına ait örnek görüntüler

Tablo 4.2. Buğday verisetinin ayrıntıları

Türkçe	İngilizce	Latince	Görüntü Sayısı
Septorya yaprak lekesi	Septoria tritici	Zymoseptoria tritici	97
Çizgi Pası (Sarı Pas)	Wheat stripe rust (Yellow Rust)	Puccinia striiformis Westend	208
Normal (Sağlıklı)	Healthy	-	102
Veri Setindeki Toplam Görüntü			407
Veri Artırma (Data Augmentation) Sonrası Toplam Görüntü			977

Mendeley Data'dan elde edilen veriler roboflow platformunda etiketlenen 407 adet buğday yaprağı görüntüsü, veri artırma teknikleri kullanılarak 977 adete çıkarılmıştır.

4.2. Çalışma Ortamı ve Uygulama Geliştirme Süreci

Teknolojinin hızla ilerlemesiyle birlikte, programlama dillerine olan ilgi de artmaktadır. C#, C++, Visual Studio.Net, Dart ve Python gibi popüler programlama dilleri arasında, özellikle açık kaynaklı ve hızla gelişen kütüphanelere sahip olan Python dili dikkat çekmektedir. Python, basit kod yapısı sayesinde öğrenmesi kolaydır ve bu yönüyle programlamaya yeni başlayanların sıkça tercih ettiği bir dildir. Ayrıca, Python, 2020 IEEE araştırmasına göre en popüler programlama dillerinden biri olarak gösterilmiştir (Cass, 2020). Yapay zeka alanında sıklıkla tercih edilen Python, Matlab, C++, Lush gibi diğer standart dillerle birlikte kullanılmaktadır. Python'da, yapay zeka uygulamaları için Keras, Tensorflow, Numpy, Pytorch, Matplotlib, Scipy, Scikit-Learn vb. kütüphaneler yaygın olarak kullanılır. Diğer dillere kıyasla Python, yüksek seviyeli yapısı, nesne yönelimli programlamaya uygunluğu ve sürekli genişleyen kütüphane havuzuyla öne çıkar. Python için IDLE, Spyder ve PyCharm gibi farklı kod düzenleyiciler mevcuttur. Bu dil, web geliştirme, bilimsel ve matematiksel analizler, yapay zeka ve robotik gibi çeşitli alanlarda geniş kullanım imkanları sağlar.

Bu araştırma, Python programlama dilini kullanarak gerçekleştirilmiştir. Araştırmanın uygulandığı platform olarak, yüksek işlem gücü sağlayan Google Collaboratory (Colab) tercih edilmiştir. Colab'ın sunduğu Grafik İşleme Ünitesi (GPU), özellikle derin öğrenme algoritmalarının eğitim sürecinde büyük önem taşır. Çalışmada, derin öğrenme modellerinin geliştirilmesi ve eğitilmesi amacıyla Keras ve Tensorflow kütüphaneleri kullanılmıştır.

Colab ortamında, mısır için NVIDIA'nın Tesla K80 modeli GPU'su (4992 çekirdek), buğday içinde NVIDIA'nın Tesla T4 modeli donanım hızlandırıcı olarak kullanılmıştır. Bu güçlü işlemci, derin öğrenme modellerinin karmaşık hesaplamalarını hızlandırmada etkili olmuştur. Araştırmada, mısır veri seti için ResNet mimarisinin farklı derinliklerdeki modelleri olan ResNet50, ResNet101 ve ResNet152, buğday veri seti için YOLO farklı hızlarındaki YOLO-v5s ve YOLO-v8 çeşitli iterasyonlarda çalıştırılarak performansları karşılaştırılmıştır.

4.2.1. ResNet modelleri ve eğitim süreçleri

ResNet 50, ResNet101 ve ResNet 152 modellerinin eğitimi sırasında kullanılan küme büyüklüğü, tek seferde modeli eğitmek için kullanılacak örnek sayısını belirtmektedir. Bütün veri kümesinin modelden bir kez geçmesi ise bir devir veya tur (epoch) olarak adlandırılmaktadır.

4.2.2. Mısır veri setinin hazırlanması ve eğitim süreci

Veri setinde bulunan görüntülerin orijinal boyutları 256x256 pikseldir. Ancak, ResNet-50/101/152 önceden eğitilmiş modeller için, görüntüler 224x224 boyutlarına yeniden ölçeklendirilmiştir. Bu ölçeklendirme, ResNet'in 224x224x3 boyutlarında resimleri girdi olarak kabul etmesi gerekliliğinden kaynaklanmaktadır. Veri setindeki toplam 4.188 görüntüden, eğitim seti için %80'lik bir kısım (3.351 görüntü) ve doğrulama seti için %20'lik bir kısım (837 görüntü) ayrılmıştır.

4.2.3. Mısır eğitim sürecinin detayları ve hiper parametre ayarlamaları

Mısır veriseti için 3.351 örneklik veri kümesi üzerinde yapılan çalışmalarda, küme büyüklüğü 16 olarak belirlenmiştir. Bu durum, her bir devirde yapay sinir ağının 210 kez güncellenmesine neden olmaktadır. Uygulanan modelin geliştirilmesi için yapılan hiper parametrik ayarlamalar (hyperparameter tuning), en optimum katsayılar ve ağırlıkların bulunmasına odaklanmıştır. Kodlamada kullanılan ResNet50, ResNet101 ve ResNet152 modelleri ile yapılan farklı iterasyonlar, eğitim parametreleri ve elde edilen değerler Tablo 4.3'te gösterilmiştir.

Tablo 4.3. Mısır için ResNet eğitim parametre ve değerleri

Parametre	Değer
Görüntü boyutu (Image size)	224*224
Küme büyüklüğü (Batch size)	16
Devir / Tur (Epoch)	50
Sınıflandırma (Classes)	4

4.2.4. Buğday tanımlamasında yolo eğitim parametreleri ve değerleri

YOLO modelinin buğday tanımlama ve sınıflandırmasında kullanılan eğitim parametreleri ve bu parametrelere ait değerler Tablo 4.4'te incelenmiştir.

Modelin eğitim sürecinde kullanılan görüntü boyutu, 416x416 olarak belirlenmiştir. Bu boyut, modelin detay algılama kapasitesi ve işleme hızı üzerinde etkili olmuştur. Küme büyüklüğü, modelin her eğitim adımında işleyeceği görüntü sayısını ifade eder ve bu çalışmada 16 olarak ayarlanmıştır. Bu parametre, eğitim sürecinin verimliliğini ve bellek kullanımını etkilemektedir. Eğitim sürecinde model, veri seti üzerinde 50 epoch boyunca eğitilmiştir. Belirlenen epoch sayısı, modelin eğitim verilerini öğrenme kapasitesini yansıtmakta ve aşırı eğitime (overfitting) karşı bir dengelenme görevi görmektedir. Sınıflandırma parametresi altında, modelin ayırt etmesi gereken farklı buğday türleri veya durumlarının sayısı, bu çalışmada 3 olarak belirlenmiştir. Bu parametre, modelin sınıflandırma kabiliyetinin kapsamını ve detayını belirlemektedir. Bu parametrelerin tümü, YOLO modelinin buğday tanımlama ve sınıflandırma başarısını doğrudan etkileyen önemli faktörler olarak değerlendirilmiştir.

Tablo 4.4. Buğday için YOLO eğitim parametre ve değerleri


Parametre	Değer
Görüntü boyutu (Image size)	416*416
Küme büyüklüğü (Batch size)	16
Devir / Tur (Epoch)	50
Sınıflandırma (Classes)	3

4.2.5. Nesne tespiti için veri seti hazırlığı ve etiketleme süreci

Nesne tespiti, bilgisayar görüşü ve yapay zeka alanında kritik bir öneme sahip bir alt disiplindir. CNN'ler bu sürecin temel bileşenlerinden biri olarak, sınıflandırma ve yerleştirme görevlerinde etkin bir şekilde kullanılmaktadır (Wang vd., 2020). CNN'lerin başarılı bir şekilde kullanılması, özellikle YOLO gibi algoritmaların performansını belirleyen önemli bir faktördür. YOLOv5 ve YOLOv8 modelleri, eğitim

sırasında veri setindeki görüntüleri doğru bir şekilde tanıyıp tespit edebilmek için etiketlenmiş ve sınıflandırılmış verilere ihtiyaç duyar.

Bu süreç, tanımlanacak nesnenin etrafına sınırlayıcı bir kutu yerleştirilmesi, yani "Labeling - etiketleme" işlemi ile başlar. Roboflow gibi platformlar kullanılarak gerçekleştirilen bu etiketleme işlemi, görüntülerin belirli algoritmalara uygun formatlarda işlenmesini sağlar. Örneğin, buğday yaprağındaki hastalıkların tespiti için Septorya yaprak lekesi, Sarı Pas ve Normal (Sağlıklı) gibi sınıflarla etiketlenen bölgeler, görüntülerde büyük bir dikkat ve hassasiyetle işaretlenir. İşaretlenen bu bölgeler, daha sonra YOLOv8 ve YOLOv5 formatlarına uygun şekilde dışa aktarılır. Şekil 4.3'te bu sürecin ekran görüntüsünü sunulmaktadır.



Şekil 4. 3. Roboflow ile etiketleme işleminin ekran görüntüsü

Eğitim sürecinde, VGGNet (Simonyan ve Zisserman, 2014), GoogleNet (Szegedy vd., 2015), AlexNet (Krizhevsky vd., 2017), ResNet (He vd., 2016) ve YOLO (Redmon vd., 2016) gibi CNN mimarileri öznitelik çıkarımında kullanılmaktadır. YOLO mimarilerinin

güçlü yönleri, bu CNN'ler tarafından sağlanan derin ve zengin özniteliklerle birleştirilerek nesnelerin doğru bir şekilde tespit edilmesi ve sınıflandırılması amaçlanmaktadır. ResNet, derin öğrenme modellerindeki "kaybolan gradyan" sorununu çözerken daha derin ağ yapıları oluşturur. Buna karşılık, YOLO modelleri, sınırlayıcı kutuların doğru tahmin edilmesinde hız ve doğruluk dengesi sunar.

Bu birleşik yaklaşım, nesne tespiti alanında modelin genel performansını artırmakta ve algoritmanın gerçek dünya verileri üzerinde daha iyi genelleme yapabilmesini sağlamaktadır. Doğru etiketlenmiş ve sınıflandırılmış veri setlerinin bu modellerin eğitiminde kullanılması, öğrenilen özniteliklerin kalitesini ve tespit edilen nesnelerin doğruluğunu önemli ölçüde artırmaktadır.

4.2.6. Buğday veri setinin genişletilmesi ve zenginleştirilmesi

Buğday hastalıklarının tespiti için kullanılan veri seti, roboflow ortamında görüntü veri artırma teknikleri ile genişletilmiştir. Başlangıçta 407 görüntü içeren veri seti, uygulanan çeşitli veri artırma yöntemleriyle 977 adede çıkarılmıştır. Bu teknikler, modelin genelleme yeteneğini artırmak ve eğitim sürecindeki çeşitliliği simüle etmek için seçilmiştir.

Veri seti ön işleme tabi tutularak, yeniden boyutlandırma işlemi ile 640x640 piksel boyutlarına getirilmiştir, bu da eğitim sürecinde modelin hızlı ve etkili çalışmasını sağlar.

Uygulanan Veri Artırma Yöntemleri

- **Gri Tonlamalı Dönüşüm:** Görüntülerin %20'sine rastgele olarak gri tonlama uygulanmıştır. Bu, modelin renkten bağımsız özellikleri öğrenmesine yardımcı olur.
- **Bulanıklaştırma:** Resimlerin bir kısmına 3 piksele kadar bulanıklaştırma efekti eklenmiştir. Bu, modelin odak dışı ve düşük çözünürlüklü görüntülerde performansını test etmeyi amaçlar.
- **Gürültü Ekleme:** Piksellerin %5'ine kadar gürültü eklenerek, modelin gürültülü koşullarda da nesneleri tanıma kabiliyetinin güçlendirilmesi hedeflenmiştir.

Şekil 4.4'te, uygulanan veri artırma yöntemleri sonucunda elde edilen farklı görüntü versiyonlarını göstermektedir.



Şekil 4. 4. Veri artırma yöntemleriyle işlenmiş görüntüler

Bu veri artırma stratejileri, modelin daha geniş ve temsil edici bir veri seti üzerinde eğitim yapmasını sağlamıştır. Algoritmanın farklı görüntüleme koşulları altında etkili bir şekilde nesne tespiti yapabilmesi sağlamaktadır. Bu zenginleştirme işlemleri, modelin gerçek dünya verileri üzerindeki doğruluk oranını ve genelleme kabiliyetini artırarak, buğday hastalıklarının tespiti için daha güvenilir ve dayanıklı bir yapay zeka modelinin geliştirilmesine katkıda bulunmuştur.

5. BULGULAR

5.1. Mısır İçin Bulgular

Bu çalışmada, mısır görüntülerinden oluşan bir veri seti ele alınmış, eğitim ve doğrulama amacıyla iki ayrı gruba ayrılmıştır. Veri seti, toplamda 4.188 görüntü içermekte olup, bunların 3.351'i eğitim, 837'si ise doğrulama grubuna dahil edilmiştir. ResNet mimarisinin farklı derinliklerdeki modelleri olan ResNet-50, ResNet-101 ve ResNet-152'nin karşılaştırmaları yapılmış, ResNet-50 modeli, %85,30 oranında bir başarı sergilemişken, ResNet-101 modelinin başarısı aynı parametreler altında %94,56'ya yükselerek önemli bir iyileşme kaydedilmiştir. ResNet-152 modeli ise %94,14 başarı oranı ile benzer bir performans sergilemiştir, elde edilen sonuçlar Tablo 5.1'de sunulmuştur.

Tablo 5.1. Mısır için ResNet modellerinin test sonuçları

Model	Epoch	Eğitim seti, %80	Test seti, %20	Test Başarısı
ResNet 50	50	3.351 Görüntü	837 Görüntü	% 85,30
ResNet 101	50	3.351 Görüntü	837 Görüntü	% 94,56
ResNet 152	50	3.351 Görüntü	837 Görüntü	% 94,14

Bu bulgular, ResNet modellerinin derinliğinin artmasıyla, belirli bir noktaya kadar modelin genel performansının iyileşebileceğini ortaya koymaktadır. Ancak, ResNet-152 modelinin ResNet-101'e göre daha düşük bir başarı yüzdesine sahip olması, derinliğin her zaman daha yüksek doğruluk anlamına gelmeyebileceğini göstermektedir. Bu durum, modelin karmaşıklığı ile işlem yükü arasında dengeli bir seçimin önemini vurgulamaktadır.


5.2. Mısır için ResNet grafiklerinin bulguları, analizi ve yorumu

ResNet 50/101/152 modellerinin başarı oranı ve kayıp oranı üzerine metrikler sırasıyla Şekil 5.1, Şekil 5.2 ve Şekil 5.3'te gösterilmiştir.

Başarı Oranı (Accuracy) Grafiği: Mavi çizgi, modelin eğitim veri seti üzerindeki doğruluğunu temsil etmektedir. Grafikte görüldüğü üzere, başarı oranı başlangıçta hızla

artmış ve yaklaşık 10. epochtan sonra stabil bir artış göstermiştir. Kırmızı çizgi, modelin doğrulama veri seti üzerindeki performansını göstermektedir. Eğitim başarısına kıyasla biraz daha düşük olan doğrulama başarısı, belli bir düzeyde dalgalanmalar göstermiş, ancak genel bir yükseliş trendi izlemiştir.

Eğitim ve doğrulama başarısı arasındaki ufak fark, modelin hafif bir aşırı uydurma (overfitting) durumuna işaret edebilir, ancak bu fark azdır ve modelin genel olarak iyi genelleme yapabildiğini gösterir.




Şekil 5.1. Resnet50 modelinin eğitim başarımları ve kayıplarının grafiksel gösterimi

Kayıp (Loss) Grafiği: Mor çizgi, modelin eğitim seti üzerindeki hata miktarını temsil eder. Bu değer, eğitim süreci boyunca hızla azalmış ve belirli bir seviyede sabitlenmiştir. Yeşil çizgi, modelin doğrulama veri seti üzerindeki hata miktarını gösterir. İlk epochlarda büyük dalgalanmalar göstermiş, ancak zamanla azalarak stabil bir seviyeye ulaşmıştır. Eğitim kaybının, doğrulama kaybının altında stabil bir şekilde seyretmesi, modelin eğitim verilerine iyi uyduğunu ve doğrulama veri setinde de uygun bir performans sergilediğini gösterir.

Genel olarak, bu grafikler ResNet50 modelinin eğitim sürecinde başarılı bir şekilde öğrendiğini ve doğrulama setinde iyi bir genelleme yaptığını göstermektedir. Başarı oranı ve kaybın zamanla stabil bir duruma gelmesi, modelin uygun şekilde eğitildiğini ve eğitim döngüsü boyunca istikrarlı bir iyileşme kaydettiğini işaret eder. Bununla birlikte, eğitim ve doğrulama değerleri arasında gözlemlenen ufak farklar, modelin


hiperparametrelerinin ince ayarını ve potansiyel olarak daha fazla veri ile eğitimin yapılmasını gerektirebilir.



Şekil 5.2. Resnet101 modelinin eğitim başarımları ve kayıplarının grafiksel gösterimi

Başarı Oranı (Accuracy): Eğitim Başarısı (Mavi Eğri): Eğitimdeki başarı oranı, başlangıçta hızlı bir artış göstermiş ve yaklaşık olarak %96 civarında stabil bir seviyede kalmıştır. Doğrulama Başarısı (Kırmızı Eğri): Eğitim başarısına kıyasla, doğrulama başarısı daha dalgalı bir seyir izlemiş ve %92 ile %94 arasında bir değişkenlik göstermiştir.

Kayıp (Loss): Eğitim Kaybı (Yeşil Eğri): Modelin eğitim kaybı, hızla düşerek düşük bir değerde sabitlenmiştir; bu, modelin eğitim verilerini iyi öğrendiğini göstermektedir. Doğrulama Kaybı (Mor Eğri): Doğrulama kaybı başlangıçta düşük olmakla birlikte, zamanla dalgalanmalar göstermiş, ancak genel eğilim düşük kalmıştır. Eğitim kaybının altında sabitlenmemesi, aşırı uyum (overfitting) belirtisi olabilir.



Şekil 5.3. Resnet152 modelinin eğitim başarımları ve kayıplarının grafiksel gösterimi

Başarı Oranı (Accuracy): Eğitim başarısı (mavi eğri), zaman içinde artarak %98 civarında stabil bir seviyeye ulaşmış ve bu seviyede sabitlenmiştir. Bu, modelin eğitim sürecinde öğrenme kabiliyetinin yüksek olduğunu göstermektedir. Doğrulama başarısı (kırmızı eğri), eğitim başarısına benzer bir artış göstermiş, ancak %92 ile %94 arasında bir dalgalanma ile kararlı bir seviyede kalmıştır. Bu durum, modelin eğitim verilerine göre doğrulama verilerinde bir miktar genelleme hatası ile karşılaştığını göstermektedir.

Kayıp (Loss): Eğitim kaybı (yeşil eğri), modelin eğitim sürecinde hızla iyileştiğini ve çok düşük bir kayıp seviyesine ulaştığını göstermektedir. Bu, modelin eğitim verilerini iyi öğrendiğini ve hatasız bir şekilde tahminlerde bulunabildiğini gösterir. Doğrulama kaybı (mor eğri), eğitim kaybı gibi hızlı bir düşüş göstermiş, ancak zaman içinde belirli bir seviyede artış gösteren bir eğilim gözlemlenmiştir. Bu eğilim, modelin doğrulama verileri üzerindeki performansının belirli bir tutarlılıkta olmadığını ve zamanla aşırı uydurmaya (overfitting) eğilimli olabileceğini işaret edebilir.

Modelin doğrulama verilerindeki başarısı ve kaybı, eğitim verilerine göre daha fazla dalgalanma göstermesi, modelin eğitim verilerine aşırı uyum sağladığı ve doğrulama verilerinde beklenen performansı göstermekte zorlandığı yorumunu desteklemektedir. Bu, genelleme hatasının azaltılması ve modelin daha iyi genelleme yapabilmesi için hiperparametrelerin ince ayarlanması veya eğitim veri setinin genişletilmesi gibi ek adımların atılması gerektiğini göstermektedir.

5.2.1. Mısır için ResNet101 modelinin karşılaştırmalı başarı analizi

Bu araştırmada, mısır veri setinin eğitim ve doğrulama bölümleri kullanılarak çeşitli derin öğrenme modellerinin performansları incelenmiştir. Araştırmanın odak noktası olan ResNet101 modeli, %94,56'lık bir başarı oranı ile diğer tüm modelleri geride bırakarak en yüksek performansı sergilemiştir. Elde edilen bu sonuç, literatürde yer alan benzer çalışmalarla karşılaştırılmış ve bulgular Tablo 5.2'de özetlenmiştir.

Tablo 5.2 incelendiğinde, literatürdeki EfficientNetB5 ve çeşitli CNN modelleri yanında, VGG mimarisinin farklı makine öğrenimi algoritmalarıyla (Xgboost ve RF) yapılan kombinasyonları da kıyaslanmıştır. Bu karşılaştırmada, Göksu vd. (2021) tarafından raporlanan EfficientNetB5 modeli %92,12, CNN modeli %89,88 başarı göstermiş; Hassan vd. (2021) tarafından bildirilen VGG-Xgboost kombinasyonu %94,22, VGG-RF kombinasyonu %91,02 ve VGG19 modeli ise %88,42 başarı sergilemiştir. Ancak, bu çalışmada önerilen ResNet101 modeli, yukarıda belirtilen tüm yöntemler arasında en yüksek başarıyı elde eden model olarak belirlenmiştir.

Tablo 5.2. Mısır için diğer modellerle ResNet101 karşılaştırılması

Referans	Model	Başarı (%)
(Göksu vd., 2021)	EfficientNetB5	92,12
(Göksu vd., 2021)	CNN	89,88
(Hassan vd., 2021)	VGG ile Xgboost	94,22
(Hassan vd., 2021)	VGG ile RF	91,02
(Hassan vd., 2021)	VGG19	88,42
Önerilen	ResNet 101	94,56

Bu veriler, ResNet101 modelinin derin öğrenme tabanlı nesne tespiti alanındaki potansiyelini ve aynı verisetini kullanan literatürde yer alan diğer modellerle kıyaslandığında üstünlüğünü ortaya koymaktadır. Ayrıca, bu bulgular, derin öğrenme mimarilerinin ve bunların karmaşık görsel görevlerdeki uygulanabilirliklerinin detaylı bir şekilde incelenmesinin gerekliliğini vurgulamaktadır. Bu süreç, ResNet modellerinin derinliklerinin performans üzerindeki etkilerinin incelenmesi açısından önemlidir. Her modelin farklı katman sayıları ve yapısal özelliklerinin, nesne tespiti ve sınıflandırma gibi görevlerde modelin başarı oranına etkisi olabilmektedir. Bu bağlamda, çeşitli

derinliklerdeki modellerin karşılaştırılması, belirli bir veri seti ve görev için en uygun modelin belirlenmesinde kritik bir rol üstlenmektedir.

5.3. Buğday İçin Bulgular

Nesne tespiti alanında derin öğrenme modelleri arasında önemli bir karşılaştırma, YOLO ailesinin iki farklı versiyonu olan YOLOv5s ve YOLOv8 modellerinin performanslarının incelenmesiyle gerçekleştirilmiştir. Her iki model, aynı veri seti üzerinde eşit sayıda devirde (50 epoch) eğitilmiştir. Eğitim seti, doğrulama seti ve test seti boyutları yüzdelik olarak aynı tutularak (%88, %8 ve %4 sırasıyla) model performansları doğrudan karşılaştırılabilir hale getirilmiştir. Performans metrikleri olarak, mAP (mean Average Precision) değerlerinin yanı sıra, precision (doğruluk) ve recall (hassasiyet) oranları incelenmiştir. YOLOv8, tüm metriklerde YOLOv5s'e göre belirgin bir üstünlük sergilemiş, bu da onun nesne tespiti görevlerinde daha güçlü bir model olduğunu işaret etmektedir (Tablo 5.3).

Tablo 5.3. Buğday için YOLOv5s ve YOLOv8 karşılaştırılması

Model Özelliği	YOLOv5s	YOLOv8
Epoch / Devir	50	50
Eğitim Seti	855 Görüntü (%88)	855 Görüntü (%88)
Doğrulama Seti	81 Görüntü (%8)	81 Görüntü (%8)
Test Seti	41 Görüntü (%4)	41 Görüntü (%4)
mAP50	0,735	0,934
mAP50-95	0,317	0,662
Precision all / Doğruluk genel	0,689	0,954
Recall all / Hassasiyet genel	0,704	0,880

Nesne tespiti çalışmalarında, YOLO ailesinin iki modeli; YOLOv5s ve YOLOv8'in performansları karşılaştırılmıştır. Her iki model de 50 devir süresince, %88 eğitim, %8 doğrulama ve %4 test seti dağılımı ile eğitilmiştir. YOLOv8 modelinin mAP50 değeri %93,4 olarak ölçülürken, YOLOv5s modelinde bu değer %73,5'tir. mAP50-95 ölçümünde YOLOv8, %66,2 ile YOLOv5s modelinin %31,7'sine kıyasla yüksek bir performans göstermiştir. Doğruluk (precision) oranı YOLOv8 için %95,4, YOLOv5s için

%68,9; hassasiyet (recall) oranı ise YOLOv8 için %88, YOLOv5s için %70,4 olarak kaydedilmiştir.

Bu değerler, YOLOv8 modelinin nesneleri tanıma konusunda daha doğru ve tutarlı olduğunu; küçük detayları dahi ayırt etmede YOLOv5s modeline göre daha başarılı olduğunu ortaya koymaktadır. Doğruluk ve hassasiyet metriklerindeki yüksek skorlar, YOLOv8'in gerçek pozitifleri tanımlama ve kaçırmama konusunda daha yetkin olduğunu göstermektedir. Model performanslarının adil bir karşılaştırma temelinde değerlendirildiği bu çalışmada, YOLOv8'in özellikle yüksek doğruluk ve hassasiyet gerektiren uygulamalar için daha uygun olduğu sonucuna varılmıştır. YOLOv5s modeli ise, daha az kaynak tüketimiyle hızın daha kritik olduğu senaryolarda tercih edilebilir. Genel olarak, YOLOv8'in performans değerleri, onun nesne tespitindeki karmaşık görevlerde daha etkili olduğunu göstermektedir; ancak, uygulamanın gereksinimlerine ve kaynak kısıtlamalarına bağlı olarak, YOLOv5s hala değerli bir alternatif olarak kalmaktadır.

Tablo 5.4. Buğday için YOLO model karşılaştırması tablosu

Model Özelliği	YOLOv5s	YOLOv8
Katman Sayısı	182	168 (Füzyon sonrası)
Parametre Sayısı	7.251.912	11.126.745
Genel Performans Metrikleri		
Precision (Genel)	0,689	0,954
Recall (Genel)	0,704	0,880
mAP50	0,735	0,934
mAP50-95	0,317	0,662
Sınıf Bazında Performans		
Sağlıklı (P; R)	P: 0,619; R: 0.466	P: 1.000; R: 0,802
Septoria (P; R)	P: 0,710; R: 0.929	P: 0,922; R: 0,929
Çizgili Pas (P; R)	P: 0,738; R: 0.717	P: 0,939; R: 0,909
Uygulama Alanları	Daha az kaynak gerektiren durumlar	Yüksek performans gerektiren alanlar

Genel Analiz: Tablo 5.4'te veriler baz alınıp analiz edildiğinde YOLOv8, YOLOv5'e göre daha fazla katmana ve parametreye sahiptir, bu da onun daha karmaşık ve ayrıntılı öğrenme yeteneğine işaret eder.

YOLOv8, genel precision, recall ve mAP50 değerlerinde YOLOv5'ten üstündür, bu da onun nesne tespitinde daha hassas ve güvenilir olduğunu gösterir.

Sınıf bazında performans metriklerinde YOLOv8, her üç sınıfta da YOLOv5'ten daha iyi sonuçlar vermiştir. Özellikle sağlıklı sınıf için %100 precision oranı dikkat çekicidir.

YOLOv8'in işlem hızı, yüksek performansı korurken hızlı çıkarım süreleri sunar, bu da onu gerçek zamanlı uygulamalar için uygun kılar.

YOLOv5s, kaynak kısıtlı ortamlar ve hızın önemli olduğu durumlar için uygunken, YOLOv8 daha karmaşık ve hassas tespit gerektiren alanlar için daha uygun bir seçenektir.

Model Kompleksitesi: YOLOv8, YOLOv5'e göre daha fazla parametre içeriyor. Bu, YOLOv8'in daha karmaşık bir model olduğunu ve potansiyel olarak daha iyi öğrenme yeteneğine sahip olduğunu gösterir.

Genel Performans: YOLOv8, YOLOv5'e göre daha yüksek precision, recall ve mAP değerlerine sahiptir. Bu, YOLOv8'in nesne tespitinde daha doğru sonuçlar ürettiğini göstermektedir.

Hız: YOLOv8'in saniyede yaptığı işlem sayısı, gerçek zamanlı uygulamalar için yeterli düzeydedir. YOLOv5'in hız bilgisi eksik olduğundan, doğrudan bir karşılaştırma yapmak zordur.

Uygulama Senaryoları: YOLOv8'in daha yüksek performans metrikleri, onu hassas tespit gerektiren uygulamalar için daha uygun bir seçenek haline getirir. Öte yandan, YOLOv5 daha az karmaşık olduğu için kaynak kısıtlı ortamlarda veya daha hızlı işlem gerektiren durumlarda tercih edilebilir.

Sonuç olarak, YOLOv8, genel performans açısından YOLOv5'i aştığı görünmektedir. Ancak, her iki modelin de uygulama bağlamında ve özel gereksinimlere göre avantajları

ve dezavantajları vardır. Uygulamanın gerektirdiği özelliklere bağlı olarak doğru model seçimi yapmak önemlidir.

Tablo 5.5. YOLOv5s ve YOLOv8 model özetleri arasındaki karşılaştırma


Model Özelliği	YOLOv5s	YOLOv8
Katman Sayısı	182	168 (Füzyon sonrası)
Parametre Sayısı	7.251.912	11.126.745

YOLOv5s modeli, 182 katmandan oluşur ve toplamda yaklaşık 7.251 milyon parametreye sahiptir. Bu model, YOLO serisinin daha hafif sürümlerinden biridir ve genellikle daha hızlı çıkarım süreleri ve daha az bellek tüketimi ile ilişkilendirilir. Dolayısıyla, kaynak sınırlamaları olan uygulamalar için tercih edilebilir.

YOLOv8 modeli ise 168 katman ile biraz daha az katmana sahip olmasına rağmen, füzyon işlemi sonucu daha fazla parametreye sahip olduğu belirtilmiştir: yaklaşık 11.126 milyon parametre. Bu, genellikle katmanların birleştirilmesi ve basitleştirilmesi anlamına gelir, bu da teorik olarak modelin daha etkili olmasını sağlar. Ancak, daha fazla parametre genellikle daha fazla hesaplama yükü ve bellek gereksinimi anlamına gelir. Bu, YOLOv8'in daha karmaşık veya zorlu görevler için uyarlandığını ve daha yüksek doğruluk oranlarına ulaşabileceğini gösterir.

5.3.1. Buğday için YOLO grafiklerinin bulguları, analizi ve yorumu

Modelin öğrenme performansı ve kayıpların azalması üzerine yapılan bu çalışmada, nesne tespit modelinin eğitim ve doğrulama veri setleri üzerindeki kutu, nesne ve sınıflandırma kayıplarının yanı sıra, kesinlik ve duyarlılık gibi metrikleri YOLOv5 için Şekil 5.4'te değerlendirilmiştir.



Şekil 5.4. Yolov5 nesne tanıma modelinin eğitim sürecindeki performans metrikleri

Kutu Kaybı (Box Loss): Eğitim Kutu Kaybı (üst sol): Model, nesnelerin sınırlayıcı kutularını tahmin ederken zamanla kaybını önemli ölçüde azaltmıştır. Bu, modelin eğitim veri setindeki nesnelerin konumlarını giderek daha iyi anladığını gösterir. Doğrulama Kutu Kaybı (alt sol): Doğrulama veri seti üzerindeki kutu kaybı da düşüş göstermiş, ancak eğitim veri setine göre biraz daha yüksek bir kayıpla stabil hale gelmiştir. Bu, modelin eğitim verisine göre doğrulama verisinde biraz daha az performans gösterdiğini işaret edebilir.

Nesne Kaybı (Object Loss): Eğitim Nesne Kaybı (üst orta sol): Nesnelerin varlığını tahmin ederken modelin kaybı, eğitim süreci boyunca düşmüştür. Doğrulama Nesne Kaybı (alt orta sol): Doğrulama nesne kaybı, eğitim nesne kaybıyla benzer bir eğilim göstermiştir fakat daha fazla dalgalanma göstermektedir. Bu dalgalanmalar, doğrulama setinin model tarafından eşit derecede iyi öğrenilmediğini gösterebilir.

Sınıflandırma Kaybı (Classification Loss): Eğitim Sınıflandırma Kaybı (üst orta): Modelin nesnelerin sınıflarını doğru sınıflandırma yeteneği, eğitim boyunca gelişmiş ve kayıp düşmüştür. Doğrulama Sınıflandırma Kaybı (alt orta): Doğrulama sınıflandırma kaybı da benzer şekilde düşmüş ancak eğitim setine göre daha yüksek bir değerde sabitlenmiştir. Bu, bazı sınıflandırma hatalarının düzeltilmesi gerektiğini gösterir.


Metrikler: Kesinlik (Precision) (üst orta sağ): Model, pozitif olarak iddia ettiği nesnelerin ne kadarını doğru bir şekilde tespit ettiğini gösterir. Kesinlik, eğitim süreci boyunca dalgalanmalar göstermiş fakat genel bir artış trendine sahiptir. Duyarlılık (Recall) (üst sağ): Tüm doğru nesnelerin ne kadarının tespit edildiğini gösterir. Duyarlılık da kesinlik gibi dalgalanmalar göstermiştir, bu da modelin bazı doğru nesneleri kaçırdığını gösterir.

mAP@0.5 (alt orta sağ): Modelin tespit ettiği nesnelerin doğruluk oranının, IoU eşiği 0,5 olarak ayarlandığında hesaplanan ortalama kesinliği. mAP@0.5 değeri zamanla artmış ve yüksek bir değere ulaşmıştır, bu iyi bir sınıflandırma performansını gösterir.

mAP@0.5:0.95 (en alt sağ): Bu metrik, modelin çeşitli IoU eşiklerindeki performansının ortalamasını alır ve genellikle modelin genel doğruluğunun daha kapsamlı bir ölçüsüdür. Bu değer de zamanla istikrarlı bir şekilde artmıştır, bu da modelin genel olarak güvenilir olduğunu gösterir.

Genel yorum olarak Şekil 5.4'teki grafikler incelendiğinde, modelin eğitim sürecinde genel olarak iyi bir öğrenme performansı gösterdiği ve kayıpların düştüğü, metriklerin ise yükseldiği görülmektedir. Ancak, doğrulama kayıplarının ve metriklerindeki dalgalanmalar, modelin aşırı uyum (overfitting) eğilimi olabileceğini veya doğrulama veri setinin çeşitliliği ve zorluğu hakkında ipuçları verebilir. Bu durum, modelin genelleme yeteneğinin daha da iyileştirilmesi gerektiğine işaret edebilir.

Nesne tespit modelinin eğitim ve doğrulama veri setleri üzerindeki kutu, nesne ve sınıflandırma kayıplarının yanı sıra, kesinlik ve duyarlılık gibi metrikleri YOLOv8 için Şekil 5.5'te değerlendirilmiştir.



Şekil 5.5. Yolov8 nesne tanıma modelinin eğitim sürecindeki performans metrikleri

Kutu Kaybı (Box Loss): Eğitim Kutu Kaybı (üst sol): Modelin sınırlayıcı kutu koordinatlarını tahmin etme yeteneğinin zamanla geliştiğini ve kaybın düzenli bir şekilde azaldığını gösterir. Doğrulama Kutu Kaybı (alt sol): Doğrulama veri setindeki kutu kaybı, eğitimdekinden daha yüksek başlangıç değerleri gösteriyor ve eğitim sürecinde değişken bir düşüş sergiliyor, bu durum doğrulama veri setinin model tarafından eşit bir biçimde genelleştirilemediğini işaret edebilir.

Sınıflandırma Kaybı (Classification Loss): Eğitim Sınıflandırma Kaybı (üst orta sol): Modelin nesneleri sınıflandırma doğruluğu, eğitim boyunca önemli ölçüde iyileşmiş ve düşmüştür. Doğrulama Sınıflandırma Kaybı (alt orta sol): Doğrulama setindeki sınıflandırma kaybı, eğitim setindekilere kıyasla daha az düşmüş ve yüksek dalgalanmalar göstermiştir.

Derin Özellik Kaybı (Deep Feature Loss): Eğitim Derin Özellik Kaybı (üst orta): Modelin derin özellikleri öğrenme yeteneği gelişmiş, bu kayıp düşüş trendi göstermiştir. Doğrulama Derin Özellik Kaybı (alt orta): Doğrulama setindeki derin özellik kaybı, eğitim setine benzer bir düşüş göstermiş fakat daha yüksek değerler sergilemiştir.

Performans Metrikleri: Kesinlik (Precision) (üst orta sağ): Modelin pozitif tahminlerinin gerçekten ne kadar doğru olduğunu gösterir. Kesinlik, eğitim süreci boyunca genel bir artış göstermiştir, bu iyi bir performans göstergesidir. Duyarlılık


(Recall) (üst sağ): Modelin gerçekte pozitif olan tüm örnekleri ne kadar iyi tespit ettiğini gösterir. Duyarlılık, yüksek bir seviyede istikrar göstermiştir.

mAP@0.5 (alt orta sağ): Modelin belirli bir IoU eşiği (0.5) için kesinlik ve duyarlılık ortalamasını gösterir ve zamanla artmıştır, bu da modelin güvenilirliğini işaret eder.

mAP@0.5:0.95 (alt sağ): Modelin bir dizi IoU eşiğindeki ortalama performansını gösterir ve genel doğruluğun kapsamlı bir ölçüsüdür. Bu değer, eğitim süreci boyunca sürekli bir artış göstermiştir.

Bu analize göre, modelin eğitim ve doğrulama süreçleri boyunca genel bir iyileşme eğilimi gösterdiği ancak doğrulama setindeki performansının eğitim setine göre daha az istikrarlı olduğu görülmektedir. Kesinlik ve duyarlılık metriklerinin yüksek değerleri, modelin iyi bir performans gösterdiğine işaret etse de doğrulama kayıplarındaki dalgalanmalar modelin bazı durumlarda genelleme yapmakta zorlandığına dair işaretler verebilir. Bu, modelin aşırı uydurma (overfitting) riskine karşı dikkatle incelenmesi gerektiğini gösterir ve modelin daha fazla genelleştirilebilir olması için veri setinin çeşitlendirilmesi veya düzenleme tekniklerinin uygulanması gibi stratejiler önerilebilir.

Yolo v8 Karışıklık Matrisi (Confusion Matrix)



Şekil 5.6. Yolo v8 karışıklık matrisi

Sınıflar:

- Sağlıklı (healthy)
- Septorya (septoria)
- Çizgi Pası (stripe_rust)
- Arka Plan (background)

Doğru Pozitifler (True Positives)

- Sağlıklı sınıfı için modelin doğru pozitif oranı %81'dir.
- Septorya sınıfı için modelin doğru pozitif oranı %93'tür, bu oldukça yüksek bir performansı gösterir.
- Çizgi pası için doğru pozitif oran %89'dur.

Yanlış Pozitifler (False Positives)

- Sağlıklı sınıfı, septorya ve çizgi pası sınıflarına %2 ve arka plana %25 oranında yanlış pozitif olarak sınıflandırılmıştır.
- Septorya sınıfı, sağlıklı sınıfa %2 oranında yanlış pozitif olarak sınıflandırılmıştır.
- Çizgi pası sınıfı, sağlıklı ve septorya sınıflarına sırasıyla %5 ve %7 oranında yanlış pozitif olarak sınıflandırılmıştır.
- Arka plan sınıfı, sağlıklı ve septorya sınıflarına sırasıyla %14 ve %7 oranında yanlış pozitif olarak sınıflandırılmıştır.

Yanlış Negatifler (False Negatives)

- Sağlıklı sınıfının yanlış negatif oranı %14, bu sınıfın arka plan ile karıştırılma olasılığını gösterir.
- Septorya sınıfının yanlış negatif oranı yok denecek kadar azdır (%2), bu da bu sınıfın diğer sınıflarla çok az karıştırıldığını gösterir.
- Çizgi pası, sağlıklı ve septorya sınıflarına sırasıyla %5 ve %7 oranında yanlış negatif olarak sınıflandırılmıştır.

Genel Analiz: Buğday veri seti üzerinde yapılan inceleme sonucunda, 'sağlıklı', 'septoria' ve 'çizgili pas' olarak adlandırılan üç sınıfın tanımlanmış olduğu saptanmıştır (Bkz. Tablo

4.2). Roboflow aracılığıyla gerçekleştirilen etiketleme işlemi sırasında, bu üç sınıfa ait etiketlerin uygulanmış olduğu gözlemlenmiştir (Bkz. Şekil 4.3). YOLO modelinin eğitim parametreleri ve değerleri belirlenirken, yalnızca bu üç sınıfın tanımlandığı kayıt altına alınmıştır (Bkz. Tablo 4.4). Fakat YOLOv8 karışıklık matrisi incelendiğinde (Şekil 5.6), 'arkaplan' adı verilen beklenmedik bir dördüncü sınıfın var olduğu tespit edilmiştir. YOLOv8 modelinin veya eğitim sırasında kullanılan araçların, belirlenemeyen bir nesneyi varsayılan olarak 'arkaplan' sınıfına atama ihtimali düşünülmüştür.

Demirleme kutusu kullanılmayan YOLOv8 yapısı göz önüne alındığında, modelin, demirleme kutularının sabit boyut ve oranlarına bağlı kalmaksızın nesnelerin merkezlerini doğrudan tahmin edebildiği ortaya çıkmıştır (Bkz. Şekil 3.11). Bu özellik, modelin, her pikselin bir nesneye ait olup olmadığını ya da arkaplan olarak mı değerlendirilmesi gerektiğine karar verme kabiliyetini geliştirmesine katkıda bulunmuş olabilir. Buna göre, modelin çıktıları doğrudan nesnelerin sınıflarını ve konumlarını yansıtmakta ve 'arkaplan' sınıfı da model tarafından öğrenilmiş bir konsept olarak değerlendirilebilir. Programa 'arkaplan' sınıfı eklenmemiş olsa dahi, modelin eğitim aşamasında, veri setindeki etiketlenmemiş ya da arkaplan olarak değerlendirilebilecek alanları otomatik olarak 'arkaplan' olarak sınıflandırıyor olması muhtemeldir.

Genel Yorum: Model, septorya ve çizgi pası sınıflarını oldukça yüksek doğrulukla sınıflandırmıştır. Bununla birlikte, sağlıklı sınıf ve arka plan arasındaki karışıklık, bu iki sınıf arasındaki sınırların model tarafından daha az net anlaşıldığını göstermektedir. Modelin genel olarak yüksek duyarlılık gösterdiği ancak bazı özel durumlarda yanlış pozitiflerin ortaya çıkabileceği anlaşılmaktadır. Modelin hassasiyetini ve genelleştirme yeteneğini artırmak için ek veri seti çeşitlendirmesi, ağırlık düzenlemesi veya diğer iyileştirme teknikleri düşünülebilir.

5.3.2. YOLO modeli ile bitki yapraklarının sağlık durumunun tespiti

Yolo v8 modelinin bitki yaprakları üzerindeki nesne tespitini gösteren genişletilmiş eğitim örneğine ait görsel Şekil 5.7’de gösterilmiştir. Görüntüde, bitki yapraklarının üzerindeki 'sağlıklı' ve 'stripe_rust' (çizgi pası) durumlarını belirleyen sınırlayıcı kutular (bounding boxes) görülmektedir. Her kutu, modelin tahmin ettiği sınıfı ve sınıfın tahmini güvenilirliğini (kesinlik/confidence score) ifade eder.



Şekil 5.7. Yolov8'in yapraklardaki hastalık tespiti gösteren eğitim örneği

Analiz

Çoğu tespit 'stripe_rust' sınıfına aittir ve güvenilirlik skorları genellikle yüksektir (0,6 – 0,9 arası), bu durum modelin bu sınıfı tespit etme konusunda oldukça güvenilir olduğunu gösterir. 'Healthy' (sağlıklı) sınıfı için yapılan tespitlerin sayısı daha azdır ve güvenilirlik skorları düşüktür (örneğin bir tespit 0,3 olarak görülmektedir), bu durum modelin sağlıklı yaprakları tespit etme konusunda daha az güvenilir olduğunu veya eğitim veri setinde yeterli örnek bulunmadığını gösterebilir. Bazı yapraklar birden fazla kez 'stripe_rust' olarak işaretlenmiş, bu durum modelin aynı nesneyi birden fazla kez tespit ettiğini ve bu durumun iyileştirilmesi gerektiğini belirtir. Sınırlayıcı kutuların yerleştirilmesi genellikle doğru olsa da bazı durumlarda yanlış pozitifler (sağlıklı yaprakların stripe_rust olarak işaretlenmesi) ve yanlış negatifler (stripe_rust'un sağlıklı olarak işaretlenmesi) göze çarpmaktadır.

Öneriler

Modelin daha dengeli bir doğruluk ve kesinlikle tespit yapabilmesi için sağlıklı yaprakların daha fazla eğitim örneği ile desteklenmesi faydalı olabilir. Tespit edilen nesnelerin çakışmasını azaltmak için non-maximum suppression (NMS) gibi tekniklerin ayarlarının gözden geçirilmesi önerilir. Yanlış pozitif ve yanlış negatif tespitlerin azaltılması için modelin hiperparametrelerinin ince ayar yapılması ve eğitim veri setinin genişletilmesi düşünülebilir.

5.3.3. Buğday için YOLOv8 modelinin karşılaştırmalı başarı analizi

Buğday tanıma ve sınıflandırma görevleri için geliştirilen çeşitli algoritmaların performanslarını karşılaştıran bu çalışmada, özellikle derin öğrenme tabanlı modellerin doğruluk (precision), hassasiyet (recall) ve mAP@50 gibi temel metrikler üzerinden değerlendirilmesi yapılmıştır. Gao vd. (2023) ve Mitra vd. (2023) tarafından yapılan çalışmalarla karşılaştırıldığında, önerilen YOLOv8 modelinin, Random Forest, XG Boost ve Ada Boost gibi geleneksel makine öğrenimi algoritmalarının yanı sıra, YOLOv5 gibi diğer derin öğrenme modellerine kıyasla nasıl bir performans sergilediği Tablo 5.6'da özetlenmiştir. Bu karşılaştırma, YOLOv8 modelinin buğday tespitindeki etkinliğini ve aynı verisetini kullanan diğer yöntemler arasındaki konumunu daha net bir şekilde ortaya koymayı amaçlamaktadır (Tablo 5.6).

Tablo 5. 6. Buğday için diğer modellerle YOLOv8 karşılaştırılması

Referans	Model	Precision (%)	Recall (%)	mAP@50
(Gao vd., 2023)	Random Forest	93,26	93,22	-
(Gao vd., 2023)	XG Boost	92,56	92,56	-
(Gao vd., 2023)	Ada Boost	82,49	82,49	-
(Mitra vd., 2023)	Yolo v5	86,9	74,9	81,9
(Mitra vd., 2023)	Yolo v8	80,5	77,5	81,6
Önerilen	Yolo v8	95,4	88,0	93,4

Karar Ağaçları Tabanlı Modeller

Random Forest modeli, yüksek kesinlik ve duyarlılık oranlarına sahiptir (%93,26 ve %93,22). Bu, modelin hem pozitif hem de negatif sınıfları neredeyse eşit derecede iyi tanıdığını gösterir. Ancak, mAP@50 değeri verilmemiştir, bu da nesne tespitindeki performansı hakkında eksik bilgi anlamına gelir.

XG Boost modeli de benzer yüksek kesinlik ve duyarlılık değerlerine sahipken (%92,56), yine mAP@50 verisi eksiktir.

Ada Boost, karşılaştırılan diğer algoritmalara göre daha düşük performans gösterir (%82,49), bu da onun karmaşık veri setlerini modellemede diğerlerine göre daha az etkili olduğuna işaret edebilir.

YOLO Modelleri

Mitra vd. (2023) çalışmasında, YOLO v5 ve YOLO v8 modellemeye tabi tutulan YOLO sürümleri, mevcut bu çalışmada önerilen YOLO v8 modelinin gerisinde kalmaktadır. YOLO v5, mAP@50'de %81,9 ile ortalama bir performans sergilerken, YOLO v8 daha düşük bir mAP@50 değeri (%81,6) ile kararlılık göstermiştir.

Önerilen YOLO v8 modeli ise, diğer tüm modellere göre daha üstün performans sergilemektedir. %95,4 kesinlik ve %88,0 duyarlılık değerleriyle en yüksek mAP@50 değeri olan %93,4'e ulaşmıştır. Bu, modelin hem genel tahmin doğruluğunda hem de özellikle nesne tespitinde yüksek performans gösterdiğini göstermektedir.

Sonuç olarak, önerilen YOLO v8 modeli, buğday yaprak hastalıklarının tespiti ve sınıflandırılmasında mevcut makine öğrenmesi ve derin öğrenme modellerine göre önemli ölçüde daha iyi sonuçlar vermektedir. Bu, YOLO v8'in bu alandaki uygulamalarda tercih edilen bir model olabileceğini göstermektedir. Ancak, karar ağaçları tabanlı modellerin yüksek kesinlik ve duyarlılık değerleri, onların belirli durumlar veya veri türleri için hala değerli olabileceğini göstermektedir.

6. SONUÇ ve TARTIŞMA

Küresel ölçekte, tarımsal arazi kullanımının etkinliğinin giderek büyük bir önem kazanmaktadır. Endüstriyel faaliyetlerin artması, kırsal alanlardan şehir merkezlerine göç, iklim değişikliklerinin yol açtığı kuraklık gibi faktörler, tarım alanlarının verimli kullanılmasını zorunlu kılmaktadır. Bu bağlamda, tarımsal üretimde verimliliğin artırılması, kaynakların daha etkin kullanılması ve bitki hastalıklarının etkin bir şekilde yönetilmesi kritik hale gelmiştir. Teknolojinin ve yapay zekânın tarım sektöründe kullanımı, özellikle bitki yaprak hastalıklarının tespiti ve analizinde hayati bir rol üstlenmektedir.

Bu çalışmada, mısır yaprak hastalıklarının sınıflandırılması için derin öğrenme tabanlı ResNet modeli kullanılmıştır. ResNet-50, ResNet-101 ve ResNet-152 gibi çeşitli ResNet modelleri, Kaggle veri setinden temin edilen 4.188 adet mısır yaprağı görüntüsü üzerinde test edilmiştir. Bu testler, Google Collaboratory'nin yüksek performanslı GPU destekli ortamında yürütülmüştür. Mısır için ResNet50 ile %85,30, ResNet101 ile %94,56 ve ResNet152 ile %94,14 oranında doğruluk sağlanmıştır. Araştırma sonuçlarına göre, ResNet-101 modeli, %94,56'lık bir başarı oranı ile en etkili model olarak tespit edilmiştir. Bu sonuç, ResNet modellerinin tarımsal hastalık tespiti alanındaki etkinlik potansiyelini ortaya koymaktadır.

Bu çalışmada, buğday yaprak hastalıklarının tespiti için geliştirilen YOLO v8 modelinin, benzer amaçla yapılmış ve aynı verisetini kullanan önceki çalışmalardan daha üstün performans sergilediği gözlemlenmiştir. Modelin başarısının altında yatan temel faktörlerden biri, kullanılan veri artırma yöntemleridir. Veri artırma, modelin daha geniş ve çeşitli bir veri seti üzerinde eğitilmesini sağlayarak, genelleme yeteneğini ve dolayısıyla doğruluk oranını artırmıştır.

Ayrıca, buğday yaprak hastalıklarının tespiti amacıyla YOLO modelleri üzerinde bir başka çalışma yapılmıştır. Bu çalışmada, YOLOv5s modeli %68,9 kesinlik ve %70,4 duyarlılık değerleriyle, %73,5 civarında bir genel doğruluk oranına ulaşırken, YOLOv8 modeli %95,4 kesinlik ve %88 duyarlılık ile %93,4 mAP50 değerine erişmiştir. Bu sonuçlar, YOLOv8 modelinin YOLOv5s modeline göre nesne tanıma performansında önemli bir üstünlük sağladığını göstermektedir. YOLOv8'in başarısının altında yatan

temel faktörler arasında, veri artırma tekniklerinin kullanılması yer almaktadır. Bu teknikler, modelin daha çeşitli veri setleri üzerinde eğitilmesine olanak tanıyarak genelleme yeteneğini ve dolayısıyla doğruluk oranını artırmıştır.

Çalışma ayrıca, ResNet-50/101/152 ve YOLO-v5s/v8 modellerinin karşılaştırmalı analizini içererek, mısır için ResNet101 modelinin ve buğday için YOLOv8 modelinin benzer veri setleriyle kıyaslandığında en yüksek başarı oranlarına ulaştığını ortaya koymuştur. ResNet101 ve YOLOv8 modellerinin yüksek doğruluk oranları, bu modellerin benzer veri setleri üzerinde etkili olduğunu ve tarımsal uygulamalarda kullanılabileceğini göstermektedir. Ancak, bu teknolojilerin daha geniş bir alanda uygulanabilmesi için ek araştırmalara ve geliştirmelere ihtiyaç duyulmaktadır. Özellikle, farklı bitki türleri ve hastalık türleri üzerinde yapılan çalışmalar, bu teknolojilerin uygulama alanını genişletebilir.

Bu çalışmaların sonuçları, yapay zeka tabanlı tarım uygulamalarının, özellikle bitki hastalıklarının tespiti ve sınıflandırılmasında, kritik bir öneme sahip olduğunu vurgulamaktadır. ResNet-101 ve YOLOv8 modellerinin sağladığı üstün performans, bu alandaki gelecek araştırmalara yön verme potansiyeline sahip olup, yapay zeka tabanlı tarımsal hastalık tespit sistemlerinin gelişimine önemli katkılarda bulunabilir. Yapay zekânın tarımdaki artan kullanımıyla, hastalıklı bitki yapraklarının erken tespiti ve analizi sayesinde, tarımsal üretimin verimliliği artırılabilir. Bu gelişmeler, teknoloji tabanlı tarımın ilerlemesine katkı sağlayacak ve çiftçilere maliyet düşürme ve verimlilik artışı gibi avantajlar sunacaktır.

7. ÖNERİLER

Bu araştırma, ResNet ve YOLO gibi gelişmiş derin öğrenme modellerinin tarımsal uygulamalarda ne derecede etkili olduğunu gözler önüne sermektedir. Bu çerçevede, gelecekteki çalışmalar için detaylı ve kapsamlı öneriler aşağıda sunulmuştur:

Model Çeşitliliği ve Optimizasyonu: Derin öğrenme alanındaki mevcut literatür, çeşitli modellerin tarımsal hastalık tespitindeki etkinliğine işaret etmektedir. Bu bağlamda, ResNet ve YOLO modelleri dışında, GAN'lar (Generative Adversarial Networks) ve LSTM (Long Short-Term Memory) gibi farklı derin öğrenme algoritmalarının tarımsal hastalık tespiti amacıyla kullanılması önerilir. Bu, model çeşitliliğini artırarak ve farklı yaklaşımların etkinliğini kıyaslayarak, hastalık tespitindeki başarı oranını optimize edebilir.

Genişletilmiş Veri Setleri ve Çoklu Bitki Türleri: Bu çalışma, mısır ve buğday gibi temel tarım ürünleri üzerine yoğunlaşmıştır; ancak, arpa, mercimek, soya fasulyesi gibi diğer bitki türleri için de özelleştirilmiş veri setleri geliştirilmesi önerilir. Bu, modelin genelleştirme kabiliyetini artırarak, geniş bir bitki türleri yelpazesinde etkili olmasını sağlayabilir. Ayrıca, farklı iklim koşulları ve coğrafi bölgelerden toplanan veri setlerinin entegrasyonu, modelin çeşitli çevresel faktörlere karşı dayanıklılığını test etmek için de önemlidir.

Zirai İlaçlama Dronları ve Uzaktan Algılama Teknolojilerinin Entegrasyonu: Zirai ilaçlama dronları (ZİHA) ve diğer insansız hava araçlarının kullanımı, bitki hastalıklarının erken evrelerde tespit edilmesinde kritik bir rol oynayabilir. Uydu görüntüleri ve dronlardan elde edilen veriler, hastalıkların yayılım haritasını çıkarmak ve hızlı müdahale stratejileri geliştirmek için kullanılabilir. Bu veriler, tarım alanlarının geniş bir coğrafi alanda izlenmesini ve hastalıkların yayılma eğilimlerinin belirlenmesini sağlayabilir. Üreticilere, hastalıklı bölgelerin GPS koordinatları ile birlikte bildirilmesi, hızlı ve odaklanmış müdahalelere imkân tanır.

Uzman Sistemler ve Akıllı Tarım Uygulamaları: Tarımsal ilaç kullanımı ve dozajının belirlenmesinde uzman sistemlerin ve akıllı tarım uygulamalarının kullanımı, tarımın sürdürülebilirliğini artıracak ve çevre üzerindeki olumsuz etkileri azaltacak şekilde

planlanabilir. Yapay zeka tabanlı sistemler, bitki hastalıklarının tespiti, ilaçlama stratejilerinin belirlenmesi ve su kaynaklarının verimli kullanımında kritik bir role sahip olabilir.

Karşılaştırmalı Analiz ve Model Uyarlaması: Farklı tarım ürünleri üzerine yapılan çalışmalar, çeşitli modellerin etkinliğinin kıyaslanması için zengin bir veri kaynağı sunmaktadır. Bu çalışma, mısır ve buğday gibi temel tarım ürünlerine odaklanmıştır. Ancak, literatürde mevcut olan çeşitli veri setleri ve modellerle yapılabilecek karşılaştırmalı analizler, bu modellerin diğer tarım ürünleri üzerindeki etkinliğini de değerlendirmeye olanak tanır. Böylece, geniş bir yelpazede tarım ürünleri için özelleştirilmiş çözümler geliştirilebilir.

Bu öneriler, derin öğrenme ve yapay zeka teknolojilerinin tarımsal uygulamalarda kullanımının gelecekteki yönünü belirleyecek ve bu alandaki araştırmalar için yeni perspektifler sunacaktır.

KAYNAKLAR

- Acıbuca, R. (2010). Dünya Nüfus Artışı ve Gıda Güvenliği. *Tarım Ekonomisi Dergisi*, 24(2), 133-147.
- Adem, K., Kavalcı Yılmaz, E., Ölmez, F., Bakour, K. ve Çelik, K., (2024). Buğdayda Sarı Pas Hastalığının Tespitine Yönelik Derin Öğrenme Modellerinde Evrişim Katmanı Sayısı ve Aktivasyon Fonksiyonlarının Sınıflandırma Üzerindeki Etkisinin Araştırılması. *1. Bilsel International Korykos Scientific Researches And Innovation Congress*, Mersin, 27-28 January 2024, 724-734.
- Ahmed, S., Hasan, M. B., Ahmed, T., Sony, M. R. K. & Kabir, M. H. (2022). Less is more: Lighter and Faster Deep Neural Architecture for Tomato Leaf Disease Classification. *IEEE Access*, 10, 68868-68884. doi: 10.1109/ACCESS.2022.3187203
- Akan, K. (2019). Sarı Pas (*Puccinia striiformis* f. sp. *tritici*) Hastalığına Dayanıklı Makarnalık Buğday Hatlarının Geliştirilmesi. *Türk Tarım ve Doğa Bilimleri Dergisi*, 6(4), 661-670. doi: 10.30910/turkjans.633548
- Akar, F., Aydın, Y. ve Bülgen, A. (2022). RESNET Modelleri ile Mısır Yapraklarında Hastalık Tespiti. *In International Informatics Congress (IC2022)*, Batman, 17 Şubat 2022, 381-391.
- Akarken, N. ve Taş, T. (2014). Bazı Mısır Hatlarının Yaprak Klorofil Yoğunluklarının Belirlenmesi. *IMAC 2014 Uluslararası Mezopotamya Tarım Kongresi*, Diyarbakır, 22-25 Eylül 2014, 967.
- Aksoy, B., Halis, H. D. ve Salman, O. K. M. (2020). Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3), 194-210. doi: 10.47933/ijeir.772514
- Aktaş, M. ve Arslan, M. (2017). Buğdayda Yaprak Hastalıkları ve Mücadele Yöntemleri. *Türkiye Ziraat Dergisi*, 54(1), 1-10.
- Alaiso, S., Backman, J. & Visala, A. (2013). Ant Colony Optimization for Scheduling of Agricultural Contracting Work. *IFAC Proceedings Volumes*, 46(18), 133-137. doi:10.3182/20130828-2-SF-3019.00041
- Ali, R. B., Bouadila, S. & Mami, A. (2018). Development of a Fuzzy Logic Controller applied to an agricultural greenhouse experimentally validated. *Applied Thermal Engineering*, 141, 798-810. doi: 10.1016/j.applthermaleng.2018.06.014
- Amin, H., Darwish, A., Hassanien, A. E. & Soliman, M. (2022). End-to-End Deep Learning Model for Corn Leaf Disease Classification. *IEEE Access*, 10, 31103-31115. doi: 10.1109/ACCESS.2022.3159678.

- Araújo, S.O., Peres, R. S., Barata, J., Lidon, F. & Ramalho, J.C. (2021). Characterising the Agriculture 4.0 Landscape-Emerging Trends, Challenges and Opportunities. *Agronomy*, 11 (4), 667. doi: 10.3390/agronomy11040667
- Arya, M. S., Anjali, K. & Unni, D. (2018). Detection of Unhealthy Plant Leaves Using Image Processing and Genetic Algorithm With Arduino. *2018 International Conference on Power, Signals, Control and Computation (EPSCICON)*, 1-5, Thrissur, India. doi: 10.1109/EPSCICON.2018.8379584
- Aslan, M. (2021). Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, 23, 540-546. doi: 10.31590/ejosat.883787
- Aydoğdu, M., ve Akan, K. (2023). Bazı ekmeklik ve makarnalık buğday çeşitlerinin farklı fenolojik dönemlerinde sarı pas (*Puccinia striiformis* f. sp. *tritici*) hastalık şiddeti değişiminin çok bantlı (Hyperspectral) veriler kullanılarak İncelenmesi. *Harran Tarım ve Gıda Bilimleri Dergisi*, 27(2), 189-206. doi: 10.29050/harranziraat.1244516
- Barrero, O. & Perdomo, S.A. (2018). RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. *Precision Agriculture*, 19, 809–822. doi: 10.1007/s11119-017-9558-x
- Başaran, S. ve Kılıç, M. (2019). Buğdayda Yaprak Hastalıkları. *Bitki Koruma Bülteni*, 68(1), 1-10.
- Bayer Tarım Crop Science Türkiye. (2022). Mısır Hastalıkları. <https://www.cropscience.bayer.com.tr/turkiye/tarim-haberleri/misir-hastaliklari.html>, Son erişim tarihi: 10.02.2023
- Bi, C., Xu, S., Hu, N., Zhang, S., Zhu, Z. & Yu, H. (2023). Identification Method of Corn Leaf Disease Based on Improved Mobilenetv3 Model. *Agronomy*, 13(2), 300. doi: 10.3390/agronomy13020300
- Biçgi, M. ve Karaca, İ. (2022). Nesne Tespit Algoritması (YOLOv4) Kullanarak Patates Böceğinin (*Leptinotarsa decemlineata*) (Say) Patates Bitkisi Üzerinde Tespiti ve Populasyon İzleme Olanakları. *Türk Bilim ve Mühendislik Dergisi*, 4(2), 123-129. doi: 10.55979/tjse.1210904
- Bishop, C. M. (2006). Pattern Recognition and Machine Learning. *Springer Google Schola*, 2, 5-43.
- Bock, C. H., Poole, G. H., Parker, P. E. & Gottwald, T. R. (2010). Plant Disease Severity Estimated Visually, by Digital Photography and Image Analysis, and by Hyperspectral Imaging. *Critical Reviews in Plant Sciences*, 29(2), 59-107. doi: 10.1080/07352681003617285
- Boursianis, A.D., Papadopoulou, M.S., Diamantoulakis, P., Liopa-Tsakalidi, A., Barouchas, P., Salahas G., Karagiannidis, G., Wan, S. & Goudos, S.K. (2022). Internet of Things (IoT) and Agricultural Unmanned Aerial Vehicles (UAVs) in

smart farming: A comprehensive review. *Internet of Things*, 18, 100187, doi: 10.1016/j.iot.2020.100187

Brenya, E., Hanif, I. K., Iddris, A. I., Yeboah, N. K., Umar Bawah, F., Zakaria, A. K., ... & Akoto-Adjepong, V. (2024). Convolutional Neural Network Model for Disease Detection in Corn Leaf at All Growing Stages. *Available at SSRN 4664141*. doi:10.2139/ssrn.4664141

Bronson, K. & Knezevic, I. (2016). Big Data in food and agriculture. *Big Data & Society*, 3(1). doi: 10.1177/2053951716648174

Cass, S. (2020). The top programming languages: Our latest rankings put Python on top-again-[Careers]. *IEEE Spectrum*, 57(8), 22-22. doi:10.1109/MSPEC.2020.9150550

Chang, S., Yang, G., Cheng, J., Feng, Z., Fan, Z., Ma, X., ... & Zhao, C. (2024). Recognition of wheat rusts in a field environment based on improved DenseNet. *Biosystems Engineering*, 238, 10-21. doi:10.1016/j.biosystemseng.2023.12.016

Chen, J., Chen, W., Zeb, A., Yang, S. & Zhang, D. (2022). Lightweight Inception Networks for the Recognition and Detection of Rice Plant Diseases. *IEEE Sensors Journal*, 22(14), 14628-14638. doi: 10.1109/JSEN.2022.3182304.

Ciran, A. ve Özbay, E. (2022). Ön-Eğitilmiş CNN Mimarilerinin Füzyonu ile Mısır Yaprığı Hastalıklarının Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 74-83. doi: 10.31590/ejosat.1216356

Cramer, H. H. (1967). Pflanzenschutz und Welternte. *Pflanzenschutz-Nachrichten "Bayer"*, 20(1), 1-523.

Çakmakçı, R., Salık, M.A. & Çakmakçı, S. (2023). Assessment and principles of environmentally sustainable food and agriculture systems. *Agriculture*, 13(5), 1073. doi: 10.3390/agriculture13051073

Çat, A. (2022). Tescilli Makarnalık Buğday (*Triticum durum*) Çeşitlerinin Sarı Pas (*Puccinia striiformis* f. sp. *tritici*) Hastalığına Karşı Dayanıklılığının Belirlenmesi. *Türkiye Tarımsal Araştırmalar Dergisi*, 9(2), 136-143. doi: 10.19159/tutad.1040665

Çetiner, H. (2021). Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Derin Ağ Modeli. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 442-456. doi: 10.54365/adyumbd.988049

Çırak, B. ve Yörük, A. (2016). Mekatronik Biliminin Öncüsü İsmail El - Cezeri. *Sürt Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* (4), 175-194.

Çiçek, Y., Uludag, A. ve Gülbandır, E. (2022). Şeker Pancarı Üretiminde Kullanılan Yapay Zekâ Teknikleri. *Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi*, 3(2), 54-59. doi: 10.53608/estudambilisim.1102769

- Diken. (2023). Harari: Yapay zeka insan zekasından milyonlarca kat hızlı evrimleşecek. <https://www.diken.com.tr/harari-yapay-zeka-insan-zekasindan-milyonlarca-kat-hizli-evrimlesecek/>, Son erişim tarihi: 10.02.2024
- Eğerci, Y., Öztürk, M. Ö. ve Hekimhan, H. (2021). Buğdayda septorya yaprak lekesi hastalığına (*Zymoseptoria tritici* (Desm. Quaedvlieg & Crous) karşı bazı buğday çeşitlerinin reaksiyonlarının belirlenmesi. *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 58(3), 347-354. doi: 10.20289/zfdergi.693570
- Fan, W., Yang, Y., Qi, J., Zhang, Q., Liao, C., Wen, L., ... & Zhang, D. (2024). A deep-learning-based framework for identifying and localizing multiple abnormalities and assessing cardiomegaly in chest X-ray. *Nature Communications*, 15(1), 1347. doi: 10.1038/s41467-024-45599-z
- Faridi, M., Verma, S. & Mukherjee, S. (2018). Integration of Gis, Spatial Data Mining, and Fuzzy Logic for Agricultural Intelligence. *Soft Computing: Theories and Applications: Proceedings of SoCTA 2016*, 1, 171-183. Springer Singapore. doi: 10.1007/978-981-10-5687-1_16
- Foley, J. A., Ramankutty, N., Brauman, K. A., Cassidy, E. S., Gerber, J. S., Johnston, M., ... & Zaks, D. P. (2011). Solutions for a cultivated planet. *Nature*, 478(7369), 337-342. doi:10.1038/nature10452
- Food and Agriculture Organization - FAO. (2009). How to Feed the World in 2050. https://www.fao.org/fileadmin/templates/wsfs/docs/expert_paper/How_to_Feed_the_World_in_2050.pdf, Son erişim tarihi: 15.06.2023
- Gao, R., Jin, F., Ji, M. & Zuo, Y. (2023). Research on the method of identifying the severity of wheat stripe rust based on machine vision. *Agriculture*, 13(12), 2187. doi: 10.3390/agriculture13122187
- Geetharamani, G. & Pandian, A. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers & Electrical Engineering*, 76, 323-338. doi: 10.1016/j.compeleceng.2019.04.011
- Getachew, H. & Hawi, T. (2021). Wheat leaf dataset. *Mendeley Data*, V1. doi:10.17632/wgd66f8n6h.1
- Girshick, R., Donahue, J., Darrell, T. & Malik, J. (2015). Region-Based Convolutional Networks for Accurate Object Detection and Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(1), 142–158. doi: 10.1109/TPAMI.2015.2437384
- Godfray, H. C. J., Beddington, J. R., Crute, I. R., Haddad, L., Lawrence, D., Muir, J. F., ... & Toulmin, C. (2010). Food security: the challenge of feeding 9 billion people. *Science*, 327(5967), 812-818. doi: 10.1126/science.1185383
- Göksu, M., Sünnetçi, K. M. ve Alkan, A. (2021). Derin öğrenme ağları kullanılarak mısır yapraklarında hastalık tespiti. Computer Science, *IDAP-2021: 5th International*

Artificial Intelligence and Data Processing symposium (Special), 208-216. doi: 10.53070/bbd.989305

- Haklı, H., Uğuz, H. & Cay, T. (2018). Genetic algorithm supported by expert system to solve land redistribution problem. *Expert systems*, 35(6), e12308. doi: 10.1111/exsy.12308
- Hassan, S. M., Jasinski, M., Leonowicz, Z., Jasinska, E. & Maji, A. K. (2021). Plant Disease Identification Using Shallow Convolutional Neural Network. *Agronomy*, 11(12), 2388. doi: 10.3390/agronomy11122388
- Hayıt, T. (2021). Buğdayda sarı pas (*Puccinia striiformis*) hastalığının değerlendirilmesi için görüntü işleme teknikleri kullanılarak bir karar destek sisteminin geliştirilmesi. Doktora Tezi, *Kırıkkale Üniversitesi Fen Bilimler Enstitüsü*, Kırıkkale, 5-8
- He, K., Zhang, X., Ren, S. & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, USA, 770-778, doi: 10.1109/CVPR.2016.90.
- Hosseini, M., Naeini, S. A. M., Dehghani, A. A. & Khaledian, Y. (2016). Estimation of soil mechanical resistance parameter by using particle swarm optimization, genetic algorithm and multiple regression methods. *Soil and Tillage Research*, 157, 32-42. doi: 10.1016/j.still.2015.11.004
- Intersog (2021). "AI's Powerful Duo: The Difference Between Machine Learning and Deep Learning." *Intersog Blog*. <https://intersog.co.il/blog/ais-powerful-duo-difference-between-machine-learning-and-deep-learning/>, Son erişim tarihi: 09.02.2024
- İnik, Ö. ve Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Jocher, G., Chaurasia, A. & Qiu, J. (2024). YOLO by Ultralytics. GitHub. <https://github.com/ultralytics/ultralytics> , Son erişim tarihi: 07.01.2024
- Jouini, O., Sethom, K. & Bouallegue, R. (2023). Wheat leaf disease detection using CNN in Smart Agriculture. *2023 International Wireless Communications and Mobile Computing (IWCMC)*, Marrakesh, Morocco, 1660-1665, doi: 10.1109/IWCMC58020.2023.10183348.
- Kaggle, *Corn or Maize Leaf Disease Dataset*. <https://www.kaggle.com/smaranjitghose/corn-or-maize-leaf-disease-dataset>, Son erişim tarihi: 10.01.2023
- Kale, S. S. & Patil, P. S. (2019). Data mining technology with fuzzy logic, neural networks and machine learning for agriculture. *In Data Management, Analytics and Innovation: Proceedings of ICDMAI 2018*, 2, 79-87, Springer Singapore. doi: 10.1007/978-981-13-1274-8_6

- Kamilaris, A. & Prenafeta-Boldú, F. X. (2018). A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156(3), 312–322. doi: 10.1017/S0021859618000436
- Kamilaris, A. & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90. doi: 10.1016/j.compag.2018.02.016
- Kartikeyan, P. & Shrivastava, G. (2022). Impact Evaluation of Deep Learning Models in the Context of Plant Disease Detection. *Proceedings of International Conference on Data Science and Applications: ICDSA 2021*, 1. 527-540. Springer Singapore. doi:10.1007/978-981-16-5120-5_40
- Kasinathan, T. Singaraju, D. & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, 8(3), 446-457. doi: 10.1016/j.inpa.2020.09.006
- Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhmi, M. & Gumaei, A. (2021). Automatic detection of citrus fruit and leaves diseases using deep neural network model. *IEEE Access*, 9, 112942-112954. doi: 10.1109/ACCESS.2021.3096895.
- Khawas, P., Dash, K. K., Das, A. J. & Deka, S. C. (2016). Modeling and optimization of the process parameters in vacuum drying of culinary banana (Musa ABB) slices by application of artificial neural network and genetic algorithm. *Drying Technology*, 34(4), 491-503. doi: 10.1080/07373937.2015.1060605
- Khoshnevisan, B., Rafiee, S., Iqbal, J., Shamshirband, S., Omid, M., Anuar, N.B. & Abdulwahab, A.W. (2015). A Comparative Study Between Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems for Modeling Energy Consumption in Greenhouse Tomato Production: A Case Study in Isfahan Province. *The Journal of Agricultural Science*, 17, 49-62.
- Khoshroo, A., Emrouznejad, A., Ghaffarizadeh, A., Kasraei, M. & Omid, M. (2018). Sensitivity analysis of energy inputs in crop production using artificial neural networks. *Journal of Cleaner Production*, 197, 992-998. doi: 10.1016/j.jclepro.2018.05.249
- Kızılboğa, A. Y. (2021). Yapay sinir ağları ve derin öğrenme teknikleri kullanılarak elma ve ayvada çeşitli hastalıkların tespit edilmesi. Yüksek Lisans Tezi, *Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü*, Kırıkkale, 12-16
- Kızrak, A. (2018). Derine Daha Derine: Evrişimli Sinir Ağları. [Medium]. <https://ayyucekizrak.medium.com/deri%CC%87ne-daha-deri%CC%87ne-evri%C5%9Fimli-sinir-a%C4%9Flar%C4%B1-2813a2c8b2a9> , Son erişim tarihi: 15.09.2023

- Krizhevsky, A., Sutskever, I. & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. doi: 10.1145/3065386
- Kurniasih, D., Jasmi, K. A., Basiron, B., Huda, M. & Maseleno, A. (2018). The uses of fuzzy logic method for finding agriculture and livestock value of potential village. *International Journal of Engineering & Technology*, 7(3), 1091-1095. doi: 10.14419/ijet.v7i3.12495
- LeCun, Y.; Bengio, Y. & Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436-444. doi: 10.1038/nature14539
- Li, L., Zhang, S. & Wang, B. (2021). Plant disease detection and classification by deep learning-a review. *IEEE Access*, 9, 56683-56698. doi: 10.1109/ACCESS.2021.3069646.
- Li, X. & Parrott, L. (2016). An improved Genetic Algorithm for spatial optimization of multi-objective and multi-site land use allocation *Computers, Environment and Urban Systems*, 59, 184-194. doi: 10.1016/j.compenvurbsys.2016.07.002
- Liu, B., Zhang, Y., He, D. & Li, Y. (2018). Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks. *Symmetry*, 10(1), 11. doi: 10.3390/sym10010011
- Liu, Z. W., Liang, F. N. & Liu, Y. Z. (2018). Artificial neural network modeling of biosorption process using agricultural wastes in a rotating packed bed. *Applied Thermal Engineering*, 140, 95-101. doi: 10.1016/j.applthermaleng.2018.05.029
- Maes, W.H. & Steppe, K. (2019). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in Plant Science*, 24 (2), 152-164, doi: 10.1016/j.tplants.2018.11.007
- Martinez, V.M., Gomez-Gil, F. J., Gomez-Gil, J. & Ruiz-Gonzalez, R. (2015). An Artificial Neural Network based expert system fitted with Genetic Algorithms for detecting the status of several rotary components in agro-industrial machines using a single vibration signal. *Expert Systems with Applications*, 42(17-18), 6433-6441. doi: 10.1016/j.eswa.2015.04.018
- Martos, V., Ahmad, A., Cartujo, P. & Ordoñez, J. (2021). Ensuring agricultural sustainability through remote sensing in the era of agriculture 5.0. *Applied Sciences*, 11(13), 5911. doi: 10.3390/app11135911
- Matha, T. W., Jati, A. N. & Azmi, F. (2016). Fuzzy logic as a method of decision making in automatic watering plants. *JMECS (Journal of Measurements, Electronics, Communications, and Systems)*, 2(1), 15-21. doi: 10.25124/jmecs.v2i1.1830
- McCarthy, J. (1955). Human-Level Ai Is Harder Than It Seemed.
- Mendeley Data, *Wheat leaf dataset*, <https://data.mendeley.com/datasets/wgd66f8n6h/1> ,
Son erişim tarihi: 05.01.2024

- Mitra, A., Mohanty, S. P. & Kougianos, E. (2023). aGRodet 2.0: An Automated Real-Time Approach for Multiclass Plant Disease Detection. *SN Computer Science*, 4(5), 657. doi: 10.1007/s42979-023-02076-6
- Mohanty, S. P., Hughes, D. P. & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419. doi: 10.3389/fpls.2016.01419
- Montalvo, M., Guerrero, J. M., Romeo, J., Emmi, L., Guijarro, M. & Pajares, G. (2013). Automatic expert system for weeds/crops identification in images from maize fields. *Expert Systems with Applications*, 40(1), 75-82. doi: 10.1016/j.eswa.2012.07.034
- Neog, P. P., Batra, S., Saraswat, S., Sharma, E. L., Kumar, P. P. & Pandey, A. K. (2023). A Brief Overview of Deep Learning based Techniques for the Detection of Wheat Leaf Disease: A Recent Study. *2023 7th International Conference on Intelligent Computing and Control Systems (ICICCS)*, Madurai, India, 209-217, doi: 10.1109/ICICCS56967.2023.10142846.
- Nguyen, D. C. H., Ascough II, J. C., Maier, H. R., Dandy, G. C. & Andales, A. A. (2017). Optimization of irrigation scheduling using ant colony algorithms and an advanced cropping system model. *Environmental Modelling & Software*, 97, 32-45. doi: 10.1016/j.envsoft.2017.07.002
- Oppenheim, D. & Shani, G. (2017). Potato disease classification using convolution neural networks. *Advances in Animal Biosciences*, 8(2), 244-249. doi: 10.1017/S2040470017001376
- Özer, Z., Kadioğlu, İ., Önen, H. ve Tursun, N. (2003). Herboloji (Yabancı Ot Bilimi). *Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Yayınları*, Tokat, 20 (10), 409, ISBN:975.7328.16.2
- Özgüven, M. M. (2018). The Newest Agricultural Technologies, Current Investigations in *Agriculture and Current Research*, 5 (1), 573-580.
- Palanisamy, S. & Sanjana, N. (2022). Corn Leaf Disease Detection; A Survey, *2022 International Conference on Inventive Computation Technologies (ICICT)*, Nepal. 1287-1294, doi: 10.1109/ICICT54344.2022.9850647.
- Palanisamy, S. & Sanjana, N. (2023). Corn Leaf Disease Detection Using Genetic Algorithm and Weighted Voting, *2023 2nd International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*, Coimbatore, India, 1-6, doi: 10.1109/ICAECA56562.2023.10200196.
- Patrício, D. I. & Rieder, R. (2018). Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture*, 153, 69-81. doi: 10.1016/j.compag.2018.08.001

- Paymode, A. S. & Malode, V. B. (2022). Transfer learning for multi-crop leaf disease image classification using convolutional neural networks VGG. *Artificial Intelligence in Agriculture*, 6, 23-33. doi: 10.1016/j.aiia.2021.12.002
- Polat, K. (2023). Buğday Durum Tahmin Raporu 2023. *Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü (TEPGE)*, 384, 10-13, <https://arastirma.tarimorman.gov.tr/tepge>, ISBN:978-625-94245-0-7, Son erişim tarihi: 15.02.2024
- Pretty, J. (2012). Sustainable intensification in Africa. *International Journal of Agricultural Sustainability*, 9(1), 3-4. Routledge. doi: 10.3763/ijas.2011.91ED
- Rajeena PP, F., SU, A., Moustafa, M. A. & Ali, M. A. (2023). Detecting Plant Disease in Corn Leaf Using EfficientNet Architecture-An Analytical Approach. *Electronics*, 12(8), 1938. doi: 10.3390/electronics12081938
- Raschka, S. (2016). Python Machine Learning. *Packt Publishing Ltd*. ISBN:978-1-78355-513-0
- Rashid, R., Aslam, W. & Aziz, R. (2024). An Early and Smart Detection of Corn Plant Leaf Diseases Using IoT and Deep Learning Multi-Models. *IEEE Access*. 12, 23149-23162, doi: 10.1109/ACCESS.2024.3357099
- Redmon, J., Divvala, S., Girshick, R. & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, USA, 779-788, doi: 10.1109/CVPR.2016.91.
- Roboflow. (2024). What's New in YOLOv8, <https://blog.roboflow.com/whats-new-in-yolov8/>, Son erişim tarihi: 17.02.2024
- Romeo, J., Pajares, G., Montalvo, M., Guerrero, J. M., Guijarro, M. & de la Cruz, J. M. (2013). A new Expert System for greenness identification in agricultural images. *Expert Systems with Applications*, 40(6), 2275-2286. doi: 10.1016/j.eswa.2012.10.033
- Rossini, M., Cifone, F. D., Kassem, B., Costa, F. & Portioli-Staudacher, A. (2021). Being lean: how to shape digital transformation in the manufacturing sector. *Journal of Manufacturing Technology Management*, 32(9), 239-259. doi: 10.1108/JMTM-12-2020-0467
- Saiz-Rubio, V. & Rovira-Más, F. (2020). From smart farming towards agriculture 5.0: A review on crop data management. *Agronomy*, 10(207), 1–21. doi:10.3390/agronomy10020207
- Saleem, M. H., Potgieter, J. & Arif, K. M. (2022). A performance-optimized deep learning-based plant disease detection approach for horticultural crops of New Zealand. *IEEE Access*, 10, 89798-89822. doi: 10.1109/ACCESS.2022.3201104.

- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210-229. doi: 10.1147/rd.33.0210.
- Saranya, T., Deisy, C., Sridevi, S. & Anbananthen, K.S.M. (2023). A comparative study of deep learning and Internet of Things for precision agriculture. *Engineering Applications of Artificial Intelligence*, 122, 106034. doi: 10.1016/j.engappai.2023.106034
- Savary, S., Willocquet, L., Pethybridge, S. J., Esker, P., McRoberts, N. & Nelson, A. (2019). The global burden of pathogens and pests on major food crops. *Nature Ecology & Evolution*, 3(3), 430-439. doi: 10.1038/s41559-018-0793-y
- Shaikh, T.A., Rasool, T. & Lone, F.R. (2022). Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. *Computers and Electronics in Agriculture*, 198, 107119. doi: 10.1016/j.compag.2022.107119
- Shannon, C. E. (1950). XXII. Programming a computer for playing chess. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 41(314), 256-275. doi: 10.1080/14786445008521796
- Shinde, S., Kothari, A. & Gupta, V. (2018). YOLO based human action recognition and localization. *Procedia Computer Science*, 133, 831-838. doi: 10.1016/j.procs.2018.07.112
- Sibiya, M. & Sumbwanyambe, M. (2019). A computational procedure for the recognition and classification of maize leaf diseases out of healthy leaves using convolutional neural networks. *AgriEngineering*, 1(1), 119-131. doi: 10.3390/agriengineering1010009
- Simonyan, K. & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint*, arXiv:1409.1556. doi: 10.48550/arXiv.1409.1556
- Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S. & Batra, N. (2020). PlantDoc: a dataset for visual plant disease detection. *Proceedings of the 7th ACM IKDD CoDS and 25th COMAD*. 249-253. doi: 10.1145/3371158.3371196.
- Srilakshmi, A., Madhumitha, K. & Geetha, K. (2021). MADLI: Mixture of Various Automated Deep Learning Classification for Paddy Crop Images. *In Artificial Intelligence and Technologies: Select Proceedings of ICRTAC-AIT 2020*, 395-404. Springer Singapore. doi: 10.1007/978-981-16-6448-9_40
- Staniūtė, R. & Šešok, D. (2019). A Systematic Literature Review on Image Captioning. *Applied Sciences*, 9(10), 2024. doi: 10.3390/app9102024.
- Sun, J., Yang, Y., He, X. & Wu, X. (2020). Northern maize leaf blight detection under complex field environment based on deep learning. *IEEE Access*, 8, 33679-33688. doi: 10.1109/ACCESS.2020.2973658.

- Sunil, C. K., Jaidhar, C. D. & Patil, N. (2021). Cardamom plant disease detection approach using EfficientNetV2. *IEEE Access*, 10, 789-804. doi: 10.1109/ACCESS.2021.3138920.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Rabinovich, A. & Weinberger, K. (2015). Going Deeper with Convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.
- Şahin, H. (2022). Dijital Tarım, Tarım 4.0, Akıllı Tarım, Robotik Uygulamalar ve Otonom Sistemler. *Tarım Makinaları Bilimi Dergisi*, 18(2), 68-83.
- Tarım ve Orman Bakanlığı. (2008). Ziraî Mücadele Teknik Talimatları (Cilt 1). *Tarımsal Araştırmalar ve Politikalar Genel Müdürlüğü*. <https://www.tarimorman.gov.tr/TAGEM/Belgeler/Teknik%20tal%C4%B1matlar%202008/C%C4%B0LT%201.pdf>, Son erişim tarihi: 03.01.2024
- Tarım ve Orman Bakanlığı. (2014). Mısır, Hastalık ve Zararlıları ile Mücadele. https://www.tarimorman.gov.tr/GKGM/Belgeler/Uretici_Bilgi_Kosesi/Dokumanlar/misir.pdf, Son erişim tarihi: 07.0.2023
- Terentev, A., Dolzhenko, V., Fedotov, A. & Eremenko, D. (2022). Current state of hyperspectral remote sensing for early plant disease detection: A review. *Sensors*, 22(3), 757. doi: 10.3390/s22030757
- Terven, J., Córdova-Esparza, D. M. & Romero-González, J. A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680-1716. doi: 10.3390/make5040083
- Terzi, İ., Özgüven, M. M., Altaş, Z. ve Uygun, T., (2019). Tarımda Yapay Zeka Kullanımı. *International Erciyes Agriculture, Animal Food Sciences Conference 24-27 April 2019*, 245-255. Kayseri, Turkey
- Toprak Mahsulleri Ofisi - TMO. (2009). 2009 Yılı Dünya Gıda Durumu Raporu. <https://www.tmo.gov.tr/Upload/Document/maliisler/faaliyetraporu2009.pdf>, Son erişim tarihi: 10.12.2022
- Tuncer, A. (2021). Cost-optimized hybrid convolutional neural networks for detection of plant leaf diseases. *Journal of Ambient Intelligence and Humanized Computing*, 12(2), 8625-8636. doi:10.1007/s12652-021-03289-4
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433-460. doi: 10.1093/mind/LIX.236.433
- Türkiye İstatistik Kurumu - TÜİK. (2022). Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları 2021. <https://data.tuik.gov.tr/Bulten/Index?p=Adrese-Dayali-Nufus-Kayit-Sistemi-Sonuclari-2021-45500&dil=1>, Son erişim tarihi: 05.07.2023
- Türkoğlu, M. (2019). Görüntü İşleme Tabanlı Bitki Türleri ve Hastalıkları Tanıma. Doktora Tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, Malatya

- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S. & Hanbay, D. (2020). Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. **Bitlis Eren Üniversitesi Fen Bilimleri Dergisi**, 9(1), 334-345. doi: 10.17798/bitlisfen.562101
- Vásquez, R. P., Aguilar-Lasserre, A. A., López-Segura, M. V., Rivero, L. C., Rodríguez-Duran, A. A. & Rojas-Luna, M. A. (2019). Expert system based on a fuzzy logic model for the analysis of the sustainable livestock production dynamic system. **Computers and Electronics in Agriculture**, 161, 104-120. doi: 10.1016/j.compag.2018.05.015
- Wang, Z. J., Turko, R., Shaikh, O., Park, H., Das, N., Hohman, F., Kahng, M. & Chau, D. H. P. (2020). CNN explainer: learning convolutional neural networks with interactive visualization. **IEEE Transactions on Visualization and Computer Graphics**, 27(2), 1396-1406. doi: 10.1109/TVCG.2020.3030418
- Wheeler, T. & Von Braun, J. (2013). Climate Change Impacts on Global Food Security. **Science**, 341(6145), 508-513. doi: 10.1126/science.1239402
- Xu, L., Cao, B., Zhao, F., Ning, S., Xu, P., Zhang, W. & Hou, X. (2023). Wheat leaf disease identification based on deep learning algorithms. **Physiological and Molecular Plant Pathology**, 123, 101940. doi: 10.1016/j.pmpp.2022.101940
- Yılmaz, A. (2023). Yapay Zekâ. İstanbul. **Kodlab Yayın Dağıtım Yazılım ve Eğitim Hizmetleri San. ve Tic. Ltd. Şti.** ISBN: 978-605-9118-80-4
- Zeng, Q., Ma, X., Cheng, B., Zhou, E. & Pang, W. (2020). Gans-based data augmentation for citrus disease severity detection using deep learning. **IEEE Access**, 8, 172882-172891. doi: 10.1109/ACCESS.2020.3025196.
- Zhang, D. Y., Luo, H. S., Cheng, T., Li, W. F., Zhou, X. G., Gu, C. Y. & Diao, Z. (2023). Enhancing wheat Fusarium head blight detection using rotation Yolo wheat detection network and simple spatial attention network. **Computers and Electronics in Agriculture**, 211, 107968. doi: 10.1016/j.compag.2023.107968
- Zhang, N., Wang, M. & Wang, N. (2002). Precision agriculture-a worldwide overview. **Computers and electronics in agriculture**, 36(2-3), 113-132. doi: 10.1016/S0168-1699(02)00096-0
- Zhang, Y., Lee, W. S., Li, M., Zheng, L. & Ritenour, M. A. (2018). Non-destructive recognition and classification of citrus fruit blemishes based on ant colony optimized spectral information. **Postharvest Biology and Technology**, 143, 119-128. doi: 10.1016/j.postharvbio.2018.05.004
- Zhang, Y., Li, M., Zheng, L., Qin, Q. & Lee, W. S. (2019). Spectral features extraction for estimation of soil total nitrogen content based on modified ant colony optimization algorithm. **Geoderma**, 333, 23-34. doi: 10.1016/j.geoderma.2018.07.004

Zhao, X. Y., He, Y. X., Zhang, H. T., Ding, Z. T., Zhou, C. A. & Zhang, K. X. (2024). A quality grade classification method for fresh tea leaves based on an improved YOLOv8x-SPPCSPC-CBAM model. *Scientific Reports*, 14(1), 4166. doi: 10.1038/s41598-024-54389-y

