



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME YÖNTEMİYLE PATATES YAPRAĞI
GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ**

Kenan ALMAS

**Ocak-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME YÖNTEMİYLE PATATES YAPRAĞI
GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ**

Kenan ALMAS

**Danışman
Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN**

Diğer Jüri Yeleri

Doç. Dr. Melih KUNCAN Doç. Dr. Yılmaz KAYA

**Ocak-2025
BATMAN**

TEZ KABUL VE ONAYI

Kenan ALMAS tarafından hazırlanmış olan “Derin Öğrenme Yöntemiyle Patates Yaprağı Görüntülerinden Hastalık Tespiti” adlı tez çalışması 21/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgi Teknolojileri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Melih KUNCAN

.....

Danışman

Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

.....

Üye

Doç. Dr. Yılmaz KAYA

.....

Yukarıdaki sonucu onaylarım.

Lisansüstü Eğitim Enstitüsü Müdürü V.
Dr. Öğr. Üyesi Ömer Murat ÖTER

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

İmza
Kenan ALMAS
Tarih : 21/01/2025

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME YÖNTEMİYLE PATATES YAPRAĞI GÖRÜNTÜLERİNDEN HASTALIK TESPİTİ

Kenan ALMAS

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Bilgi Teknolojileri Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

2025, 66 Sayfa

Bu tez çalışması, derin öğrenme yöntemleri kullanılarak patates görüntülerinden hastalık tespiti yapmayı amaçlamaktadır. Çalışmada, sağlıklı ve çeşitli patates hastalıklarına ait geniş ve kapsamlı bir görüntü veri seti kullanılmıştır. Farklı Evrişimli Sinir Ağı (CNN) mimarileri ve hibrit modelleri kullanılarak patates hastalıklarını tespit etmek için modeller geliştirilmiştir. Geliştirilen modeller farklı parametreler ve veri kümeleri kullanılarak eğitilmiş ve doğruluk, kesinlik gibi metrikler kullanılarak değerlendirilmiştir. Patates bitkilerinde görülen yaygın hastalıklar (geç yanıklık, erken yanıklık) tespit edilmiş ve görüntü ön işleme teknikleri kullanılarak modellerin performansı artırılmıştır. Bu çalışma, derin öğrenme yöntemlerinin patates hastalıklarının tespitinde etkili bir şekilde kullanılabileceğini göstermeyi ve bu alanda daha önce yapılan çalışmalara katkıda bulunmayı amaçlamaktadır. Çalışmada, deneysel ortamların vazgeçilmez bileşenleri olan kütüphaneler, GPU'lar, işlemciler, doğal dil işleme modelleri ve Google Colab platformu incelenmiştir ve PillantVillage veri seti kullanılmıştır. Dört farklı ResNet modeli ile görüntüler test edilmiş ve çeşitli performans metrikleriyle değerlendirilmiştir. Elde edilen bulguların, patates yetiştiriciliğinde hastalık yönetimi ve verimlilik artışı için önemli bilgiler sağlayabileceği düşünülmektedir. Yapay zeka ile görüntülerden hastalık tespiti yapılması tarım alanında yenilikler yapılmasına önayak olabileceği gibi makine-insan etkileşimine de artırıcı katkı sağlayabilir. Çalışmamız ResNet derin öğrenme modellerinin, görüntü çıkarımı alanında derin öğrenme modellerinin başarısını ve önemini vurgulamaktadır.

Anahtar Kelimeler: Derin Öğrenme, Evrişimli Sinir Ağı, Patates Hastalıkları Tespiti, Resnet, Yapay Zekâ.

ABSTRACT

MASTER THESIS

DISEASE DETECTION FROM POTATO LEAF IMAGES USING DEEP LEARNING METHODS

Kenan ALMAS

Batman University Graduate Education Institute

Department of Information Technologies

Advisor: Assist. Prof. Dr. Abdulkerim ÖZTEKİN

2025, 66 Pages

This thesis aims to detect diseases from potato images using deep learning methods. In the study, a large and comprehensive image dataset of healthy and various potato diseases was used. Models were developed to detect potato diseases using different Convolutional Neural Network (CNN) architectures and hybrid models. The developed models were trained using different parameters and datasets and evaluated using metrics such as accuracy and precision. Common diseases seen in potato plants (late blight, early blight) were detected and the performance of the models was increased using image preprocessing techniques. This study aims to show that deep learning methods can be used effectively in the detection of potato diseases and to contribute to previous studies in this field. In the study, libraries, GPUs, processors, natural language processing models and Google Colab platform, which are indispensable components of experimental environments, were examined and the PillantVillage dataset was used. Images were tested with four different ResNet models and evaluated with various performance metrics. It is thought that the findings obtained can provide important information for disease management and productivity increase in potato cultivation. Disease detection from images with artificial intelligence can lead to innovations in the field of agriculture and can also contribute to machine-human interaction. Our study emphasizes the success and importance of deep learning models in the field of image extraction, ResNet deep learning models.

Keywords: Deep Learning, Convolutional Neural Network, Potato Disease Detection, ResNets, Artificial Intelligence.

ÖN SÖZ

Çalışmalarım boyunca bana bilimsel yolculuğumda rehberlik eden, bilgisini ve deneyimini büyük bir cömertlikle paylaşan değerli hocam Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN başta olmak üzere, beni yetiştiren ve destekleyen tüm hocalarıma, aileme ve sevdiklerime sonsuz teşekkür ederim. Özellikle, eşim Peyruze ALMAS'ın sabrı ve desteği olmadan bu başarıya ulaşmam mümkün olmazdı. Çocuklarım Mehmet Kane, İrem Ayşe, Gülsüm Rağda ve Maria Nane ise bana her zaman güç veren en büyük motivasyon kaynağım olmuşlardır.

Kenan ALMAS
BATMAN-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
MS THESIS	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR.....	viii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL DİZİNİ	x
1. GİRİŞ	1
1.1.AMAÇ	5
1.2.KAPSAM.....	5
2. KAYNAK ARAŞTIRMASI	7
3. MATERYAL VE YÖNTEM.....	17
3.1. MATERYAL	17
3.2 YÖNTEMLER.....	17
3.2.1. <i>Transfer Yöntemler</i>	17
3.2.2. <i>Evrışimli Sinir Ağları (CNN)</i>	19
3.2.2.1. ResNet18.....	29
3.2.2.2. ResNET50.....	31
3.2.2.3 ResNet 152.....	33
3.2.2.4. ResNext.....	34
3.2.3 <i>Performans Ölçütleri</i>	36
3.2.3.1. Karışıklık Matrisi	36
3.2.3.2. ROC Eğrisi.....	38
3.2.3.3. Doğruluk Oranı	39
3.2.3.4. Duyarlılık / Hassasiyet.....	39
3.2.3.5. Kesinlik.....	40
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	42
5. SONUÇLAR VE ÖNERİLER	53
5.1 HEDEFLER	55
5.2. KISITLAMALAR	56
KAYNAKLAR	58

SİMGELER VE KISALTMALAR

Aşağıda, çalışmada kullanılan simge ve kısaltmaların açıklamaları yer almaktadır.

<u>Kısaltmalar</u>	<u>Açıklama</u>
ANN	: Çok Katmanlı Yapay Sinir Ağları
cGAN	: Koşullu Çekişmeli Üretici Ağlar
CNN	: Evreşimli Sinir Ağları
CoGAN	: Birleştirilmiş Çekişmeli Üretici Ağlar
ÇÜA	: Çekişmeli Üretici Ağlar
DNN	: Deep Neural Networks
DBN	: Derin İnanç Ağları
DESA	: Derin Evreşimli Sinir Ağı
DL	: Derin öğrenme (Deep Learning)
DWT	: Ayrık Dalgacık Dönüşümü
EDSR	: Geliştirilmiş Algısal Süper Çözünürlük Ağı
ESA	: Evreşimli Sinir Ağı
ELM	: Aşırı Öğrenme Makineleri
FN	: False Negative, Yanlış Negatif
FP	: False Positive, Yanlış Pozitif
G	: Üretici Ağ (Generator)
GAN	: Generative Adversarial Networks
GPU	: Graphics Processing Unit, Grafik İşleme Ünitesi
İHA	: İnsansız Hava Aracı
LSTM	: Uzun Kısa Süreli Bellek
LSQ	: Learning Vector Quantization
ML	: Makine öğrenimi (Machine Learning)
MLP	: Çok Katmanlı Algılayıcı
NLP	: Doğal Dil İşleme
PCA	: Temel Bileşen Analizi
PSO	: Parçacık Sürü Optimizasyonu
ReLU	: Rectified Linear Unit, Rektifiye Lineer Ünite
ResNet	: Residual Network, Artık Ağ
RF	: Rastgele Orman
RNN	: Recurrent Neural Network, Tekrarlayan Sinir Ağları
ROC	: Receiver Operating Characteristic, Alıcı İşletim Karakteristiği
SVM	: Destek Vektör Makineleri
TN	: True Positive, Doğru Pozitif
TP	: True Negative, Doğru Negatif
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ (Artificial Intelligence)

ÇİZELGE LİSTESİ

Çizelge 3.1. Karışıklık matrisi.....	40
Çizelge 4.1. ResNet Model Mimarileri.....	46
Çizelge 4.2. ResNet Modelleri Hiperparametre Değerleri.....	47
Çizelge 4.3. Resnet Modellerinin Doğruluk oranları.....	48
Çizelge 4.4. Resnet Modelleri ile Eğitim ve Test Veri Setinin Performans Değerleri.....	48

ŞEKİL DİZİNİ

Şekil 3.1. Sağlıklı ve Hastalıklı Patates Yaprakları.....	19
Şekil 3.2. Makine öğrenimi ve transfer öğrenme arasındaki süreç farklılığı.....	20
Şekil 3.3. CNN ağının yapısı.....	21
Şekil 3.4. Evrişim katmanının özellik çıkarımı	23
Şekil 3.5. Sigmoid aktivasyon fonksiyonu ve türevinin grafiği.....	25
Şekil 3.6. Tanh aktivasyonu fonksiyonu ve türevi.....	26
Şekil 3.7. ReLU aktivasyonu fonksiyonu ve türevi.....	27
Şekil 3.8. Leaky ReLU aktivasyonu fonksiyonu ve türevi.....	28
Şekil 3.9 2x2 Maksimum havuzlaması ve ortalama havuzlama.....	29
Şekil 3.10. Tam bağlantı katmanı.....	30
Şekil 3.11. Örnek bir Dropout Katmanı.....	31
Şekil 3.12. Düzleştirme katmanı.....	32
Şekil 3.13. ResNet18 modeli.....	33
Şekil 3.14. ResNet-50 mimarisi.....	35
Şekil 3.15. ResNet-152 mimarisi.....	37
Şekil 3.16. Resnet ile ResNext mimarilerini karşılaştırılması.....	38
Şekil 4.1. ResNet modellerine ait başarı oranları.....	50
Şekil 4.2. ResNet modellerine ait kayıp değerleri.....	51
Şekil 4.3. ResNet Modellerine ait ROC eğrileri.....	53
Şekil 4.4. Karışıklık Matrisleri Grafiği.....	54

1. GİRİŞ

Tarım, insanlığın en eski ve temel uğraşlarından biri olup, medeniyetlerin doğuşuna ve gelişimine önemli katkılar sağlamıştır. Günümüzde ise artan dünya nüfusu, iklim değişikliği ve sınırlı kaynaklar, tarımsal üretimi daha da önemli hale getirmekte ve verimliliği artırma ihtiyacını zorunlu kılmaktadır. Bu zorluklarla başa çıkabilmek ve sürdürülebilir bir gıda üretimi sağlayabilmek için teknoloji tarım sektöründe de giderek daha fazla kullanılmaya başlanmıştır. Özellikle son yıllarda yapay zekâ (YZ) alanında yaşanan hızlı gelişmeler, tarım sektöründe devrim yaratma potansiyeli taşımaktadır. Günümüzde hızla artan dünya nüfusu ve değişen tüketim alışkanlıkları, gıda arzı ve güvenliği konusunu küresel bir öncelik haline getirmiştir. Bu bağlamda, tarım sektörünün verimliliği ve sürdürülebilirliği, insanlığın geleceği açısından kritik bir öneme sahiptir. Tarım sektörünün temelini oluşturan bitkisel üretim, günümüzde yanlış ekim, yanlış sulama ve yanlış gübreleme gibi insan kaynaklı faktörlerin yanı sıra iklim değişikliği, su kıtlığı ve toprak erozyonu gibi çevresel zorluklarla da karşı karşıyadır. Bu zorluklar, tarımsal ürünlerin verimliliğini ve kalitesini olumsuz etkileyerek gıda güvenliğini tehdit etmektedir.

Teknolojik gelişmeler, tarım sektöründe bu zorlukların üstesinden gelmek ve verimliliği artırmak için yeni fırsatlar sunmaktadır. Özellikle son yıllarda hızla gelişen görüntü işleme ve derin öğrenme teknikleri, tarımsal uygulamalarda devrim yaratma potansiyeline sahiptir. Bu teknikler, bitki hastalıklarının erken teşhisi, ürün sınıflandırması, kalite kontrolü ve verim tahmini gibi birçok alanda kullanılabilir. Yapay zeka, bilgisayarlara insan gibi düşünme ve öğrenme becerileri kazandırmayı amaçlayan bir alandır. Bu alandaki makine öğrenimi ve derin öğrenme gibi dallar, tarımın birçok yönünde kullanılmaktadır. Makine öğreniminin temel fikri, bilgisayarların verilerden öğrenerek sorunları çözmesidir (Kanchana, 2022). Patates, dünya genelinde önemli bir gıda kaynağıdır ve Türkiye'de de en çok tüketilen tarım ürünlerinden birisidir. Ancak, patates üretimi ve işlenmesi sürecinde çeşitli zorluklar yaşanmaktadır. Hasat sonrası sınıflandırma ve kalite kontrol işlemleri genellikle manuel olarak yapılmakta ve bu durum standart dışı ürünler, insan kaynaklı hatalar, artan işçilik maliyetleri ve üretim israfı gibi birçok soruna yol açmaktadır (Blasco vd., 2003).

Görüntü işleme ve derin öğrenme teknikleri, patates kalite kontrolünde bu sorunların üstesinden gelmek için etkili bir çözüm sunmaktadır. Bu teknikler, renk yoğunluğu, renk dağılımı, görsel kusurlar, boyut ve şekil gibi gıda maddelerinin görsel

özelliklerini objektif olarak belirleme yeteneği (Omid vd., 2010) sayesinde hızlı, doğru ve objektif bir kalite değerlendirmesi yapılmasını sağlar. Makine öğrenimi algoritmalarının en büyük dezavantajlarından biri, verilerin önceden işlenmesi ve özelliklerin elle belirlenmesi ihtiyacıdır. Derin öğrenme ise bu zahmetli süreci ortadan kaldırarak, ham verilerden otomatik olarak anlamlı özellikler çıkarır ve böylece daha güçlü ve esnek modeller oluşturmayı mümkün kılar (Chauhan vd., 2020). Derin Öğrenme tabanlı algoritmalar, zaman ve emek tasarrufu sağladığından geleneksel makine öğrenimi yöntemlerine göre daha çok tercih edilmektedir. Bilgi teknolojilerindeki hızlı gelişmeler ve hesaplama gücündeki artış, derin öğrenmenin birçok alanda yaygınlaşmasına olanak sağlamıştır. Özellikle görüntü, metin ve ses işleme gibi alanlarda derin öğrenme modelleri, geleneksel yöntemlere göre daha başarılı sonuçlar elde etmektedir (Khan vd., 2021). Derin öğrenme, yapay sinir ağlarının daha gelişmiş bir formu olup, büyük veri setleri üzerinde eğitilerek karmaşık örüntüleri tanıma ve sınıflandırma yeteneğine sahiptir. Bu sayede, bitki hastalıklarının tespiti, ürün sınıflandırması ve kalite kontrolü gibi tarımsal uygulamalarda daha etkili sonuçlar elde edilebilmektedir (Kamilaris ve Prenafeta-Boldú, 2018).

Patates kalite kontrolünde kullanılan derin öğrenme modelleri, genellikle Evrişimli Sinir Ağları (Convolutional Neural Networks – CNN) mimarisine dayanmaktadır. CNN'ler, görüntülerdeki özellikleri otomatik olarak öğrenme ve hiyerarşik bir şekilde temsil etme yeteneğine sahiptir. Bu sayede, patateslerdeki çeşitli kusurlar, hastalıklar ve kalite özellikleri yüksek doğrulukla tespit edilebilmektedir. Derin öğrenme, çok katmanlı yapay sinir ağları (Artificial Neural Networks - ANN) aracılığıyla büyük veri kümelerinden karmaşık desenleri öğrenen bir yapay zeka alt dalıdır. Özellikle görüntü işleme alanında, evrişimli sinir ağları en yaygın kullanılan ANN türüdür. CNN'ler, ham görüntülerden otomatik olarak anlamlı özellikler çıkararak sınıflandırma gibi görevlerde üstün performans sergiler. Bu nedenle, bilgisayarlı görü alanında CNN'ler üzerindeki araştırmalar hızla artmaktadır. Geçmişte, çok katmanlı algılayıcılar, aşırı öğrenme makineleri, ResNet modelleri ve RNN (Recurrent Neural Network, Tekrarlayan sinir ağları) gibi çeşitli ANN mimarileri de görüntü sınıflandırma için kullanılmış olsa da, CNN'lerin başarısı bu alanda yeni bir çığır açmıştır (Koolagudi vd., 2018).

Derin öğrenme modellerinde, özellikle özellik çıkarma ve sınıflandırma görevlerinin birlikte öğrenildiği uçtan uca mimariler sıklıkla tercih edilmektedir. Ancak, derin sinir ağlarının (Deep Neural Networks - DNN) iç işleyişinin karmaşıklığı nedeniyle, bu modeller genellikle "kara kutu" olarak nitelendirilmektedir. Bu durum, modellerin

karar verme süreçlerinin anlaşılmasını zorlaştırmaktadır. Bu sorunu çözmek için, istatistikçiler tarafından sıklıkla kullanılan "veri modeli" ve "algoritmik model" yaklaşımları karşılaştırılmıştır. Algoritmik modeller, tahmin yapmak için en uygun algoritmayı bulmaya odaklanırken, veri modelleri verilerin yapısını ve ilişkilerini analiz etmeye yöneliktir. DNN, karmaşık veri yapılarından yüksek seviyede soyut özellikleri öğrenme yetenekleri sayesinde birçok alanda başarılı sonuçlar elde etmektedir. Ancak, bu ağların iç işleyişinin karmaşıklığı, öğrenilen özelliklerin anlaşılmasını güçleştirmektedir. Bu durum, DNN'lerin "kara kutu" olarak adlandırılmasına neden olmaktadır. Buna rağmen, çeşitli deneylerde DNN'lerin, geleneksel yöntemlere göre daha iyi performans gösterdiği gözlemlenmiştir (Zheng, Yu ve Zou, 2015).

Derin öğrenme alanında, sıralı verilerin işlenmesinde dikkat mekanizmasının ortaya çıkışı önemli bir dönüm noktası olmuştur. Bu sayede, uzun kısa süreli bellek (LSTM) ve geçitli tekrarlayan birimler (GRU) gibi modellerin performansları daha da artırılmıştır. Derin öğrenme, doğal dil işleme ve makine çevirisi gibi alanlarda çığır açıcı sonuçlar elde etmiştir (Sutskever vd., 2014). Derin sinir ağları, farklı veri tiplerine ve uygulama alanlarına göre çeşitli mimarilere sahiptir. Tekrarlayan sinir ağları (RNN) ve evrişimli sinir ağları (CNN), bu mimarilerin en bilinen örnekleridir. RNN'ler, önceki çıktılarını bir sonraki hesaplama dahil ederek zamanla değişen verileri modellemede oldukça etkilidirler. Tekrarlayan sinir ağları (RNN), her nöronun önceki zaman adımlarındaki bilgiyi hatırlamasına izin veren bir mimariye sahiptir. Bu sayede, RNN'ler zaman serileri ve doğal dil işleme gibi sıralı verilerin modellenmesinde etkili bir araç haline gelmiştir (Sherstinsky, 2019). Özellikle uzun kısa süreli bellek (LSTM) gibi RNN varyantları, uzun vadeli bağımlılıkları yakalama yetenekleri sayesinde tahmin görevlerinde önemli bir rol oynamaktadır. Derin öğrenme alanındaki gelişmeler, derin inanç ağları (DBN), evrişimli sinir ağları (CNN) ve LSTM gibi yöntemlerin çeşitli uygulamalarda başarılı bir şekilde kullanılmasına olanak sağlamıştır. Bu durum, araştırmacıların bu tekniklere olan ilgisini artırmıştır (Zhao vd., 2019). Yapay sinir ağları (YSA), özellikle evrişimli sinir ağları (CNN), görsel verilerdeki gizli özellikleri ortaya çıkarmada önemli bir rol oynamaktadır (Akhand vd., 2021). Bu alandaki gelişmeler, büyük teknoloji şirketlerinin görüntü işleme kütüphaneleri geliştirmelerine yol açmıştır. Örneğin, Intel 1999 yılında bu alanda öncü bir adım atmıştır (Open, 2022). Sonrasında Windows, Linux ve macOS gibi işletim sistemlerine sahip platformlar da görüntü işleme alanında çeşitli kütüphaneler sunmuştur.

Son yıllarda, görüntü işleme alanında derin öğrenme yöntemleri büyük bir ilgi görmektedir. Derin öğrenme, yapay sinir ağlarının çok daha karmaşık ve katmanlı bir yapıya sahip olması anlamına gelir. Bu yapı, görüntüdeki karmaşık özellikleri daha iyi öğrenmeye olanak tanır. Özellikle tıbbi görüntüleme, derin öğrenme modelleri hastalık teşhisinde etkili bir araç olarak kullanılmaktadır. Görüntülerdeki temel özellikler, görüntü işleme teknikleriyle çıkarıldıktan sonra derin öğrenme modellerine sunulur. Bu modeller, yeterli miktarda eğitim verisi ile eğitildiğinde, görüntülerdeki hastalıkları yüksek doğrulukla sınıflandırabilir. Veri ön işleme ve veri artırma teknikleri, modelin performansını artırmak için sıklıkla kullanılır (Garcia vd., 2018).

Patates hastalıklarının özelliklerine, semptomlarına ve görünümüne dayalı olarak birden fazla yönünü teşhis etme ve karakterize etme faaliyetine patates hastalığı sınıflandırması denir. Son yıllarda yapılan çalışmalar, derin öğrenme tabanlı patates kalite kontrol sistemlerinin başarısını kanıtlamıştır. Örneğin, Kılıç ve ark. (2019) tarafından yapılan bir çalışmada, derin öğrenme kullanılarak patates yapraklarındaki hastalıklar %99'un üzerinde bir doğrulukla tespit edilmiştir. Benzer şekilde, Barbedo (2018) tarafından yapılan bir çalışmada, CNN'ler kullanılarak patates yumrularındaki çeşitli kusurlar ve hastalıklar başarıyla sınıflandırılmıştır. Bu çalışmalar, derin öğrenme tabanlı görüntü işleme sistemlerinin patates kalite kontrolünde insan performansını geçebileceğini ve tarım sektöründe verimliliği artırabileceğini göstermektedir. Görüntü işleme ve derin öğrenme alanındaki hızlı gelişmeler, patates kalite kontrolünde daha da sofistike ve etkili sistemlerin geliştirilmesine olanak sağlayacaktır. Özellikle, hiperspektral görüntüleme, termal görüntüleme ve 3B görüntüleme gibi yeni görüntüleme teknolojilerinin kullanımı, patateslerin iç ve dış kalite özelliklerinin daha kapsamlı bir şekilde analiz edilmesini sağlayabilir. Ayrıca, derin öğrenme modellerinin açıklanabilirliği ve yorumlanabilirliği üzerine yapılan çalışmalar, bu modellerin karar verme süreçlerinin daha iyi anlaşılmasını ve güvenilirliğinin artırılmasını sağlayacaktır.

Görüntü işleme ve derin öğrenme teknikleri, patates kalite kontrolünde devrim yaratma potansiyeline sahiptir. Bu teknikler, hızlı, doğru ve objektif bir kalite değerlendirmesi yapılmasını sağlayarak, insan kaynaklı hataları minimize eder, işçilik maliyetlerini düşürür ve üretim verimliliğini artırır. Bu sayede, tüketicilere daha kaliteli ve güvenli patatesler sunulabilir ve gıda güvenliğine katkıda bulunulabilir. Derin öğrenme, yapay sinir ağlarının daha gelişmiş bir formu olup, büyük veri setleri üzerinde eğitilerek karmaşık görüntüleri tanıma ve sınıflandırma yeteneğine sahiptir. Bu sayede,

bitki hastalıklarının tespiti, ürün sınıflandırması ve kalite kontrolü gibi tarımsal uygulamalarda daha etkili sonuçlar elde edilebilmektedir.

1.1. Amaç

Bu tezin temel amacı, derin öğrenme yöntemleri kullanarak patates görüntülerinden hastalık tespiti yapmak ve bu alanda daha önce yapılan çalışmalara katkıda bulunmaktır. Yapay zekâ birçok alanda olduğu gibi tarım sektöründe de önemli bir rol oynamaya başlamıştır. Patates, tarım bölgelerindeki önemli sebzeler arasında yer alır ve dünya genelinde yetiştirilir ve kullanılır. Patates, birçok sağlık faydası olan yüksek proteinli bir gıdadır, ancak patates üretimini engelleyen birçok hastalık bulunmaktadır. Bu çalışmada, sağlıklı ve bilinen çeşitli patates hastalıklarını belirlemek için derin öğrenme modellerinden bir yaklaşım modeli uygulanacaktır. Patates bitkilerinde meydana gelen hastalıkların yapay zekâ teknolojisi kullanılarak tespit edilmesi mümkündür. Tezimiz, patates tarımında hastalık teşhisinin önemini vurgulayarak geleneksel yöntemlerin sınırlamalarını ele almakta ve yapay zekâ tabanlı bir çözümün potansiyel faydalarını araştırma amacındadır. Bu amaç doğrultusunda, patates hastalıklarına ait geniş ve kapsamlı bir görüntü veri seti yardımıyla, CNN mimarilerini kullanarak patates hastalıklarını tespit etmek için modeller geliştirilecek ve geliştirilen modeller farklı parametreler ve veri setleri kullanılarak eğitilecektir. Patates hastalıklarının tespitinde derin öğrenme yöntemlerinin etkinliği ve potansiyeli değerlendirilecektir.

1.2. Kapsam

Bu tez çalışması, derin öğrenme modelleri, özellikle de ResNet modelleri kullanarak patates görüntülerinden hastalık tespitine odaklanmaktadır. Çalışmada kullanılacak veri seti, sağlıklı ve çeşitli patates hastalıklarına ait geniş ve kapsamlı bir görüntü veri setinden oluşacaktır. Bu veri seti, farklı patates çeşitlerini, hastalık türlerini, hastalık şiddetini ve çekim koşullarını içerecek şekilde çeşitlilik gösterecektir.

Patates hastalıklarının tespiti için farklı ResNet mimarileri kullanılacaktır. ResNet (Residual Network), derin öğrenme alanında devrim yaratan ve görüntü sınıflandırma görevlerinde oldukça başarılı olan bir modeldir. ResNet'in temel özelliği, katmanlar arasında "artık bağlantılar" veya "kısa yollar" kullanmasıdır. Bu bağlantılar, bir katmanın

çıkışını birkaç katman ileriye atlayarak doğrudan bir sonraki katmana ekler. Bu sayede, çok derin ağlarda karşılaşılan gradyan kaybolması problemi azaltılır ve ağın eğitimi daha kolay hale gelir. Çalışmada, farklı derinlik ve yapılandırmalara sahip ResNet modelleri (ResNet-18, ResNet-50, ResNet-152, ResNeXt) değerlendirilecektir. Bu modeller, farklı parametreler ve veri setleri kullanılarak eğitilecek ve performansları karşılaştırılacaktır. Model performansı, doğruluk, hassasiyet, geri çağırma gibi metrikler kullanılarak değerlendirilecektir. Geliştirilen modeller, patates bitkilerinde görülen yaygın hastalıkları tespit etmek ve sınıflandırmak için kullanılacaktır. Bu çalışmada, ResNet modellerinin patates hastalıklarının tespitinde etkili bir şekilde kullanılabileceğini göstermeyi ve bu alanda daha önce yapılan çalışmalara katkıda bulunmayı amaçlamaktadır. Çalışma sonucunda elde edilecek bulgular, patates yetiştiriciliğinde hastalık yönetimi ve verimlilik artışı için önemli bilgiler sağlayabilir.

Özetle, bu çalışma, hibrit derin öğrenme yöntemleri yerine ResNet modellerine odaklanarak, patates hastalığı tespiti için derin öğrenme alanındaki en son gelişmelerden yararlanmayı hedeflemektedir. Çalışma sonucunda elde edilecek bulgular, patates yetiştiriciliğinde hastalık yönetimi ve verimlilik artışı için önemli bilgiler sağlayabilir.

2. KAYNAK ARAŞTIRMASI

Bitki hastalıklarının tespiti ve sınıflandırılması, tarımsal verimliliği ve gıda güvenliğini sağlamak için kritik öneme sahiptir. Geleneksel olarak uzmanlar tarafından yapılan görsel incelemeler, zaman alıcı, maliyetli ve öznel olabilmektedir. Son yıllarda, görüntü işleme ve derin öğrenme teknikleri, bitki hastalıklarının otomatik tespiti ve sınıflandırması için umut verici bir alternatif olarak ortaya çıkmıştır. Bu teknikler, bitki yapraklarındaki renk değişimleri, lekeler, desenler ve diğer görsel özellikleri analiz ederek, hastalıkları erken teşhis edebilir ve doğru bir şekilde sınıflandırabilir.

Kızıllı (2019) tarafından yapılan çalışmada, patateslerde sıklıkla görülen hastalıkların tespiti ve sınıflandırılması için görüntü işleme ve makine öğrenmesi tekniklerini kullanmaktadır. Kızıllı, çalışmasında patates verimini ve kalitesini olumsuz etkileyen erken yanıklık, geç yanıklık ve siyah çürüklük gibi yaygın hastalıklara odaklanmıştır. Bu hastalıkların erken teşhisi ve doğru sınıflandırılması, etkili mücadele yöntemlerinin uygulanabilmesi ve ürün kayıplarının en aza indirilebilmesi için kritik öneme sahiptir. Çalışmada, patates bitkilerinin yaprak ve yumrularının görüntülerinden oluşan bir veri seti kullanılmıştır. Görüntüler, farklı ışıklandırma koşullarında ve farklı hastalık şiddetlerinde çekilerek veri setinin çeşitliliği artırılmıştır. Kızıllı, öncelikle görüntüleri ön işleme tabii tutarak gürültüyü azaltmış ve görüntü kalitesini artırmıştır. Daha sonra, renk, doku ve şekil gibi özellikler görüntülerden çıkarılmıştır. Özellik çıkarma aşamasında, Renk Histogramları, Gri Seviye Eş Oluşum Matrisi (GLCM) ve Ayrık Dalgacık Dönüşümü (DWT) gibi yöntemler kullanılmıştır. Elde edilen özellikler, Destek Vektör Makineleri (SVM) gibi bir makine öğrenmesi algoritması kullanılarak sınıflandırılmıştır. Kızıllı, çalışmasında farklı SVM parametrelerini deneyerek en iyi performansı veren modeli belirlemiştir. Sonuç olarak, geliştirilen model, patates hastalıklarının %96 doğruluk oranıyla tespit etmiş ve sınıflandırmıştır.

Doğan (2021) tarafından yapılan çalışmada, domates ve elma bitkilerindeki yaprak hastalıklarının tespiti ve sınıflandırılması için derin öğrenme yöntemlerini kullanmaktadır. Doğan, çalışmasında özellikle domates ve elma bitkilerinde yaygın olarak görülen ve ekonomik kayıplara yol açan hastalıklara odaklanmıştır. Bu hastalıkların erken teşhisi ve doğru sınıflandırılması, etkili mücadele yöntemlerinin uygulanabilmesi ve ürün kayıplarının en aza indirilebilmesi için büyük önem taşımaktadır. Çalışmada, domates ve elma bitkilerinin yaprak görüntülerinden oluşan bir veri seti kullanılmıştır. Veri seti, hem sağlıklı hem de farklı hastalıklara yakalanmış

yaprakların görüntülerini içermektedir. Dođan, öncelikle görüntüleri ön işleme tabi tutarak gürültüyü azaltmış ve görüntü kalitesini artırmıştır. Daha sonra, derin öğrenme yöntemleri kullanılarak görüntülerden özellikler çıkarılmış ve sınıflandırma yapılmıştır. Dođan, çalışmasında Evrişimli Sinir Ağları (CNN) modelini kullanarak domates ve elma yapraklarındaki hastalıkları tespit etmiş ve sınıflandırmıştır. Ayrıca, Learning Vector Quantization (LVQ) algoritmasını kullanarak sınıflandırma performansını artırmayı hedeflemiştir. Çalışma sonucunda, CNN modeli ve LVQ algoritması kullanılarak elde edilen sınıflandırma doğruluk oranları karşılaştırılmıştır. Dođan, derin öğrenme yöntemlerinin bitki hastalıklarının tespiti ve sınıflandırılmasında etkili bir şekilde kullanılabileceğini göstermiştir.

Yaman ve Tuncer (2021) tarafından yapılan çalışmada, bitki hastalıklarının erken ve doğru tespiti, tarımsal verimliliği artırmak ve ürün kayıplarını en aza indirmek için kritik öneme sahiptir. Geleneksel yöntemler genellikle zaman alıcı ve uzmanlık gerektirirken, derin öğrenme tabanlı yaklaşımlar otomatik ve hızlı çözümler sunmaktadır. Bu bağlamda, fındık yaprağı hastalıklarının tespiti için derin öğrenme modellerinin kullanımı üzerine yapılan çalışmalar giderek artmaktadır. Fındık yaprağı hastalıklarının tespiti için derin öğrenme modellerinin etkinliğini incelemektedir. Bu çalışmada, sağlıklı ve hastalıklı fındık yapraklarının görüntüleri kullanılarak 17 farklı derin öğrenme modeli test edilmiştir. Performans değerlendirmesi sonucunda DarkNet53 ve ResNet101 modelleri en iyi sonuçları vermiştir. Daha sonra, bu iki modelden elde edilen özellikler birleştirilerek hibrit bir özellik çıkarımı oluşturulmuş ve sınıflandırma için Destek Vektör Makinesi (SVM) algoritması kullanılmıştır. Bu çalışma, derin öğrenme modellerinin fındık yaprağı hastalıklarının tespitinde başarılı bir şekilde kullanılabileceğini göstermektedir.

Topçu ve Güneş (2024) tarafından yapılan çalışmada, tarım sektöründe bitki hastalıklarının erken ve doğru tespiti için derin öğrenme modellerinden biri olan ResNet'in etkinliğini araştırılmaktadır. Bu çalışma, ResNet modelinin bitki yaprakları üzerindeki karmaşık özellikleri saptayarak geniş bir hastalık spektrumunu doğru bir şekilde sınıflandırabildiği gösterilmiştir. Çalışmada kullanılan veri seti, farklı bitki türleri ve hastalıklarını içeren geniş bir yelpazeyi kapsamaktadır. Bu veri seti kullanılarak eğitilen ResNet modeli, %99'luk bir başarı oranı elde etmiştir. Bu sonuç, ResNet modelinin bitki hastalıklarını tespit etmede yüksek bir doğruluk ve güvenilirlik sağladığını göstermektedir. Elde edilen bu yüksek başarı oranı, yapay zeka tabanlı görüntü işleme teknolojilerinin tarımsal uygulamalarda nasıl hayati bir rol

oynayabileceğinin bir göstergesidir. ResNet gibi derin öğrenme modelleri, bitki hastalıklarının erken teşhisinde kullanılarak, çiftçilerin zamanında müdahale etmesini ve ürün kayıplarını önlemesini sağlayabilir. Bu çalışma, ResNet modelinin bitki hastalığı tespiti alanında gelecek vaat eden bir çözüm olduğunu göstermektedir. Ancak, modelin farklı bitki türleri ve çevre koşullarında genelleştirilmesi ve gerçek dünya uygulamalarında test edilmesi gerekmektedir. Ayrıca, modelin karar verme süreçlerinin açıklanması ve yorumlanması da önemlidir. Sonuç olarak, derin öğrenme tabanlı çözümler, bitki hastalıklarının tespiti ve tarımsal üretimin iyileştirilmesi için önemli fırsatlar sunmaktadır. Bu alandaki araştırmaların devam etmesi ve yeni teknolojilerin geliştirilmesi, tarım sektöründe verimlilik artışına ve sürdürülebilirliğe önemli katkılar sağlayacaktır.

Brahimi ve arkadaşları (2017) tarafından yapılan çalışma domates bitkilerindeki hastalıkları tespit etmek ve sınıflandırmak için derin öğrenme yöntemlerini kullanmaktadır. Çalışmada, domates bitkilerinin yaprak görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, hem sağlıklı hem de farklı hastalıklara yakalanmış yaprakların görüntülerini içermektedir. Brahimi ve arkadaşları, derin öğrenme modellerini eğitmek ve test etmek için bu veri setini kullanmışlardır. Araştırmacılar, domates bitkilerindeki hastalıkları tespit etmek ve sınıflandırmak için Evrişimli Sinir Ağları (CNN) kullanmışlardır. CNN'ler, özellikle görüntü işleme alanında başarılı sonuçlar elde eden derin öğrenme modelleridir. Çalışmada, farklı CNN mimarileri denenmiş ve en iyi performansı gösteren model seçilmiştir. Seçilen model, domates bitkilerindeki hastalıkları yüksek bir doğrulukla tespit etmiş ve sınıflandırmıştır. Ayrıca, çalışma, hastalık belirtilerini görselleştirmek için yöntemler sunmaktadır.

Fuentes ve arkadaşları (2018) tarafından yapılan çalışmada, üzüm bağlarındaki hastalıkları tespit etmek ve sınıflandırmak için derin öğrenme ve dron teknolojilerini birleştiren bir sistem sunmaktadır. Çalışmada, İnsansız Hava Aracı (İHA) yani dron kullanılarak üzüm bağlarının hava görüntüleri toplanmıştır. Bu görüntüler, farklı üzüm çeşitleri ve farklı hastalıkların (külleme, mildiyö ve siyah çürüklük) bulunduğu alanları içermektedir. Fuentes ve arkadaşları, bu görüntüleri kullanarak derin öğrenme modellerini eğitmiş ve test etmişlerdir. Araştırmacılar, üzüm bağlarındaki hastalıkları tespit etmek ve sınıflandırmak için Evrişimli Sinir Ağları (CNN) kullanmışlardır. CNN'ler, özellikle görüntü işleme alanında başarılı sonuçlar elde eden derin öğrenme modelleridir. Çalışmada, farklı CNN mimarileri denenmiş ve en iyi performansı gösteren model seçilmiştir. Fuentes ve arkadaşları, geliştirdikleri sistemin, üzüm bağlarındaki

hastalıkları erken teşhis etmede ve doğru bir şekilde sınıflandırmada etkili olduğunu göstermişlerdir. Sistem, hastalıklı bölgeleri tespit ederek, ilaçlama ve diğer müdahale yöntemlerinin daha etkili bir şekilde uygulanmasını sağlayabilir. Bu da, hem verimliliği artırabilir hem de kimyasal ilaç kullanımını azaltarak çevresel etkiyi en aza indirebilir. Bu çalışma, derin öğrenme ve dron teknolojilerinin birleştirilerek tarım sektöründe bitki hastalıklarının tespiti ve yönetimi için güçlü bir araç oluşturulabileceğini göstermektedir.

Mohanty ve arkadaşları (2016) tarafından yapılan çalışmada, bitki yapraklarındaki hastalıkları tespit etmek için derin öğrenme modellerini kullanmaktadır. Bu çalışma, bitki hastalıklarının tespiti için derin öğrenmenin potansiyelini gösteren öncü çalışmalardan biridir. Mohanty ve arkadaşları, 54.306 adet görüntüden oluşan geniş bir bitki yaprağı veri seti kullanmışlardır. Bu veri seti, 14 farklı bitki türüne ait 26 farklı hastalığı içermektedir. Araştırmacılar, bitki hastalıklarını tespit etmek ve sınıflandırmak için AlexNet ve GoogLeNet gibi önceden eğitilmiş derin öğrenme modellerini kullanmışlardır. Bu modeller, ImageNet veri seti üzerinde eğitilmiş ve daha sonra bitki yaprağı veri seti üzerinde ince ayar yapılmıştır. Çalışma sonucunda, derin öğrenme modelleri, bitki yapraklarındaki hastalıkları yüksek bir doğrulukla tespit etmiş ve sınıflandırmıştır. En iyi performansı gösteren model, %99,35'lik bir doğruluk oranı elde etmiştir. Mohanty ve arkadaşlarının çalışması, derin öğrenme yöntemlerinin bitki hastalıklarının tespiti için etkili bir araç olabileceğini göstermektedir.

Bhagat ve arkadaşları (2016) tarafından yapılan çalışmada, dolmalık biber bitkilerindeki hastalıkları tespit etmek için görüntü işleme ve derin öğrenme tekniklerini kullanmaktadır. Çalışmada, dolmalık biber bitkilerinin yaprak görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, hem sağlıklı hem de farklı hastalıklara yakalanmış yaprakların görüntülerini içermektedir. Bhagat ve arkadaşları, bu görüntüleri kullanarak derin öğrenme modellerini eğitmiş ve test etmişlerdir. Araştırmacılar, dolmalık biber bitkilerindeki hastalıkları tespit etmek için Evrişimli Sinir Ağları (CNN) kullanmışlardır. CNN'ler, özellikle görüntü işleme alanında başarılı sonuçlar elde eden derin öğrenme modelleridir. Çalışmada, farklı CNN mimarileri denenmiş ve en iyi performansı gösteren model seçilmiştir. Bhagat ve arkadaşları, geliştirdikleri CNN modelinin, dolmalık biber bitkilerindeki hastalıkları yüksek bir doğrulukla tespit edebildiğini göstermişlerdir. Model, sağlıklı ve hastalıklı yaprakları %96,78'lik bir doğruluk oranıyla ayırt edebilmiştir. Bu çalışma, CNN'lerin farklı bitki türlerindeki hastalıkları tespit etmede etkili bir şekilde kullanılabilceğini göstermektedir.

Ansari ve arkadaşları (2018) tarafından yapılan çalışmada, üzüm yapraklarındaki hastalıkları tespit etmek ve sınıflandırmak için görüntü işleme, özellik çıkarma ve makine öğrenmesi tekniklerini birleştirmektedir. Çalışmada, 400 üzüm yaprağı görüntüsünden oluşan bir veri seti kullanılmıştır. Bu görüntülerin 250'si hastalıklı, 150'si ise sağlıklı yapraklara aittir. Görüntüler üzerinde öncelikle gürültü giderme, iyileştirme ve segmentasyon gibi ön işleme adımları gerçekleştirilmiştir. Daha sonra, Temel Bileşen Analizi (PCA) yöntemi kullanılarak görüntülerden özellikler çıkarılmıştır. Ansari ve arkadaşları, sınıflandırma aşamasında Parçacık Sürü Optimizasyonu (PSO) algoritması ile optimize edilmiş Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (YSA) kullanmışlardır. Ayrıca, karşılaştırma amacıyla Rastgele Orman (RF) algoritması da kullanılmıştır. Çalışma sonucunda, PSO ile optimize edilmiş SVM ve YSA algoritmalarının, üzüm yaprağı hastalıklarını sınıflandırma ve tespit etme konusunda RF algoritmasından daha iyi performans gösterdiği gözlemlenmiştir. Bu sonuç, özellik çıkarma ve optimizasyon tekniklerinin makine öğrenmesi modellerinin performansını artırabileceğini göstermektedir. Ansari ve arkadaşlarının çalışması, derin öğrenme ve özellik çıkarma tekniklerinin birleştirilerek bitki hastalıklarının tespitinde daha etkili modeller oluşturulabileceğini gösteren önemli bir örnektir.

Ashok ve arkadaşları (2019) tarafından yapılan çalışmada, domates bitkilerindeki hastalıkları tespit etmek için açık kaynaklı görüntü işleme teknikleri, segmentasyon, kümeleme ve derin öğrenmeyi birleştirmektedir. Çalışmada, domates bitkilerinin yaprak görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, hem sağlıklı hem de farklı hastalıklara yakalanmış yaprakların görüntülerini içermektedir. Ashok ve arkadaşları, bu görüntüleri analiz etmek ve hastalıklı bölgeleri tespit etmek için bir dizi görüntü işleme tekniği kullanmışlardır. İlk olarak, görüntülerdeki gürültüyü azaltmak ve görüntü kalitesini artırmak için Gauss filtresi uygulanmıştır. Daha sonra, yaprakları arka plandan ayırmak ve hastalıklı bölgeleri belirlemek için segmentasyon ve kümeleme algoritmaları kullanılmıştır. Segmentasyon işlemi, görüntüyü farklı bölgelere ayırmayı, kümeleme ise benzer özelliklere sahip pikselleri gruplandırmayı amaçlamaktadır. Hastalıklı bölgeler belirlendikten sonra, bu bölgelerden özellikler çıkarılmıştır. Özellik çıkarma aşamasında, Ayrık Dalgacık Dönüşümü (DWT) ve Gri Seviye Eş Oluşum Matrisi (GLCM) gibi yöntemler kullanılmıştır. DWT, görüntüyü farklı frekans bileşenlerine ayırırken, GLCM, pikseller arasındaki ilişkiyi analiz ederek doku özelliklerini çıkarmaktadır. Elde edilen özellikler, bir Evrişimli Sinir Ağı (CNN) modeli kullanılarak sınıflandırılmıştır. CNN modeli, domates bitkilerindeki farklı hastalıkları tespit etmek ve sınıflandırmak için

eđitilmiřtir. alıřma sonucunda, geliřtirilen sistem %98,12'lik yksek bir dođruluk oranıyla domates yapraklarındaki hastalıkları tespit etmiř ve sınıflandırmıřtır. Bu sonu, grnt n iřleme ve zellik ıkarma tekniklerinin derin đrenme modellerinin performansını artırabileceđini gstermektedir. Ashok ve arkadaşlarının alıřması, bitki hastalıklarının tespiti iin grnt iřleme, makine đrenmesi ve derin đrenme tekniklerinin etkili bir řekilde birleřtirilebileceđini gsteren nemli bir rnektir.

Tiwari ve arkadaşları (2020) tarafından yapılan alıřmada, domates bitkilerindeki hastalıkları tespit etmek iin nceden eđitilmiř derin đrenme modellerini ve zellik ıkarma tekniklerini kullanmaktadır. alıřmada, domates bitkilerinin yaprak grntlerinden oluřan bir veri seti kullanılmıřtır. Bu veri seti, sađlıklı ve farklı hastalıklara yakalanmıř yaprakların grntlerini iermektedir. Tiwari ve arkadaşları, bu grntleri analiz etmek ve hastalıkları sınıflandırmak iin transfer đrenme ynteminden faydalanmıřlardır. Transfer đrenme, bir problem iin eđitilmiř bir modelin, farklı ama ilgili bir problem iin yeniden kullanılmasını sađlar. Bu yntem, zellikle veri setinin sınırlı olduđu durumlarda model eđitimini hızlandırmak ve performansı artırmak iin etkili bir yntemdir. Tiwari ve arkadaşları, VGG19 gibi ImageNet veri seti zerinde eđitilmiř bir CNN modelini kullanarak domates yaprađı grntlerinden zellikler ıkarmıřlardır. Daha sonra, bu zellikler Lojistik Regresyon gibi bir sınıflandırıcıya girdi olarak verilerek hastalık tespiti ve sınıflandırması yapılmıřtır. alıřma sonucunda, VGG19 modeli ve Lojistik Regresyon kullanılarak %97,8'lik bir sınıflandırma dođruluđu elde edilmiřtir. Bu sonu, nceden eđitilmiř derin đrenme modellerinin transfer đrenme yoluyla bitki hastalıđı tespiti problemlerine uygulanabileceđini ve yksek dođruluk oranları sađlayabileceđini gstermektedir. Tiwari ve arkadaşlarının alıřması, derin đrenme tekniklerinin tarım alanında bitki hastalıklarının tespiti iin etkili bir řekilde kullanılabilceđini gsteren nemli bir rnektir.

Tamanna Kawcher ve arkadaşları tarafından 2020 yılında yayınlanan "Rice Leaf Disease Recognition Using Machine Learning Approach" bařlıklı alıřma, pirin bitkilerindeki yaprak hastalıklarını tespit etmek iin farklı makine đrenmesi algoritmalarını kullanmaktadır. alıřmada, pirin bitkilerinin yaprak grntlerinden oluřan bir veri seti kullanılmıřtır. Bu veri seti, sađlıklı ve farklı hastalıklara yakalanmıř yaprakların grntlerini iermektedir. Kawcher ve arkadaşları, bu grntleri analiz etmek ve hastalıkları sınıflandırmak iin eřitli makine đrenmesi algoritmalarını kullanmıřlardır. Kullanılan algoritmalar arasında K-En Yakın Komřu (KNN), J48 (Karar Ađacı), Naive Bayes ve Lojistik Regresyon yer almaktadır. KNN, bir veri noktasını en

yakın komşularının sınıfına göre sınıflandıran bir algoritmadır. J48, karar ağacı oluşturarak verileri sınıflandıran bir algoritmadır. Naive Bayes, Bayes teoremine dayalı bir olasılıklı sınıflandırma algoritmasıdır. Lojistik Regresyon ise, bağımlı değişkenin kategorik olduğu durumlarda kullanılan bir regresyon analizidir. Kawcher ve arkadaşları, bu algoritmaları pirinç yaprağı veri seti üzerinde eğitmiş ve performanslarını karşılaştırmışlardır. Her algoritma için doğruluk, hassasiyet, geri çağırma ve F1 skoru gibi metrikler hesaplanmıştır. Çalışma sonucunda, farklı makine öğrenmesi algoritmalarının pirinç yaprağı hastalıklarının tespitinde farklı performanslar gösterdiği gözlemlenmiştir. En iyi performansı gösteren algoritma, veri setine ve kullanılan parametrelere bağlı olarak değişmektedir. Kawcher ve arkadaşlarının çalışması, farklı makine öğrenmesi algoritmalarının bitki hastalığı tespiti problemlerine uygulanabileceğini ve performanslarının karşılaştırılabileceğini göstermektedir.

Anari ve arkadaşları (2021) tarafından yapılan çalışmada, bitki yapraklarındaki hastalıkları tespit etmek için derin transfer öğrenme modelini bir topluluk tekniği ile birleştirmektedir. Çalışmada, farklı bitki türlerine (elma, mısır, pamuk, üzüm, biber ve pirinç) ait sağlıklı ve hastalıklı yaprak görüntülerinden oluşan geniş bir veri seti kullanılmıştır. Anari ve arkadaşları, bu görüntüleri analiz etmek ve hastalıkları sınıflandırmak için derin öğrenme yöntemlerinden transfer öğrenmeyi kullanmışlardır. Transfer öğrenme, bir problem için eğitilmiş bir modelin, farklı ama ilgili bir problem için yeniden kullanılmasını sağlar. Bu yöntem, özellikle veri setinin sınırlı olduğu durumlarda model eğitimini hızlandırmak ve performansı artırmak için etkili bir yöntemdir. Anari ve arkadaşları, ImageNet veri seti üzerinde eğitilmiş farklı CNN mimarilerini (DenseNet121, ResNet50, InceptionV3, VGG16) kullanarak bitki yaprağı görüntülerinden özellikler çıkarmışlardır. Daha sonra, bu özellikler bir topluluk sınıflandırıcısına girdi olarak verilerek hastalık tespiti ve sınıflandırması yapılmıştır. Topluluk öğrenmesi, birden fazla modelin tahminlerini birleştirerek daha doğru ve güvenilir sonuçlar elde etmeyi amaçlayan bir makine öğrenmesi tekniğidir. Çalışma sonucunda, derin transfer öğrenme modeli ve topluluk tekniği kullanılarak %99,1'lik bir doğruluk oranı elde edilmiştir. Bu sonuç, transfer öğrenme ve topluluk tekniklerinin birleştirilerek derin öğrenme modellerinin performansının artırılabilirliğini göstermektedir. Anari ve arkadaşlarının çalışması, bitki hastalıklarının tespiti için etkili ve doğru bir yöntem sunmaktadır. Bu yöntem, farklı derin öğrenme mimarilerini ve topluluk öğrenmesini birleştirerek yüksek doğruluk oranları elde etmeyi başarmıştır.

Zaki ve arkadaşları (2021) tarafından yapılan çalışmada, domates yaprağı hastalıklarının tespiti için ince ayarlı MobileNet V2 mimarisini kullanmaktadır. Çalışmada, domates bitkilerinin yaprak görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, sağlıklı ve farklı hastalıklara yakalanmış yaprakların görüntülerini içermektedir. Zaki ve arkadaşları, bu görüntüleri analiz etmek ve hastalıkları sınıflandırmak için derin öğrenme yöntemlerinden MobileNet V2 mimarisini kullanmışlardır. MobileNet V2, özellikle mobil cihazlar gibi kaynak kısıtlı ortamlarda kullanılmak üzere tasarlanmış hafif bir CNN mimarisidir. Modelin boyutu ve hesaplama karmaşıklığı düşük olduğundan, mobil cihazlarda hızlı ve verimli bir şekilde çalışabilir. Zaki ve arkadaşları, önceden eğitilmiş MobileNet V2 modelini domates yaprağı hastalıkları veri seti üzerinde ince ayar yaparak modelin performansını optimize etmişlerdir. İnce ayar, önceden eğitilmiş bir modelin yeni bir veri seti üzerinde yeniden eğitilerek belirli bir göreve uyarlanması işlemidir. Çalışma sonucunda, ince ayarlı MobileNet V2 modeli, %90'dan fazla bir doğruluk oranıyla domates yaprağı hastalıklarını tespit etmiş ve sınıflandırmıştır. Bu sonuç, MobileNet V2 gibi hafif derin öğrenme mimarilerinin mobil cihazlar üzerinde bitki hastalığı tespiti uygulamaları için uygun olabileceğini göstermektedir. Zaki ve arkadaşlarının çalışması, derin öğrenme modellerinin tarım alanında bitki hastalıklarının tespiti için mobil cihazlar üzerinde kullanılabilirliğini gösteren önemli bir örnektir. Bu tür çalışmalar, çiftçilerin ve tarım uzmanlarının bitki hastalıklarını erken teşhis etmelerine ve hızlı bir şekilde müdahale etmelerine olanak sağlayarak ürün kayıplarını azaltmaya ve verimliliği artırmaya yardımcı olabilir.

Nagasubramanian (2019) tarafından yapılan çalışmada, çilek bitkilerindeki hastalıkları otomatik olarak tespit etmek ve sınıflandırmak için derin öğrenme yöntemlerini kullanmaktadır. Çalışmada, çilek bitkilerinin yaprak görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, sağlıklı ve farklı hastalıklara yakalanmış yaprakların görüntülerini içermektedir. Nagasubramanian, bu görüntüleri analiz etmek ve hastalıkları sınıflandırmak için Evrişimli Sinir Ağları (CNN) kullanmıştır. Nagasubramanian, tez çalışmasında mobil cihazlar üzerinde çalışabilen hafif bir CNN modeli tasarlamıştır. Bu model, sınırlı hesaplama kaynaklarına sahip cihazlarda bile hızlı ve verimli bir şekilde çalışabilir. Ayrıca, gerçek zamanlı hastalık tespiti için bir mobil uygulama geliştirilmiştir. Bu uygulama, kullanıcıların çilek bitkilerinin yapraklarının fotoğraflarını çekerek hastalık olup olmadığını kontrol etmelerini sağlar. Çalışma sonucunda, geliştirilen CNN modelinin çilek bitkilerindeki hastalıkları yüksek bir

doğrulukla tespit edebildiği ve sınıflandırabildiği gösterilmiştir. Mobil uygulama ise, kullanıcıların bitki hastalıklarını erken teşhis etmelerine ve hızlı bir şekilde müdahale etmelerine olanak sağlayarak ürün kayıplarını azaltmaya ve verimliliği artırmaya yardımcı olabilir. Nagasubramanian'ın yüksek lisans tezi, derin öğrenme yöntemlerinin bitki hastalıklarının otomatik tespiti ve tanısı için önemli bir potansiyele sahip olduğunu göstermektedir.

Baireddy (2020) tarafından çalışmada, farklı bitki türlerindeki hastalıkları tespit etmek ve sınıflandırmak için derin öğrenme yöntemlerini kullanmaktadır. Çalışmada, bitki yapraklarının görüntülerinden oluşan bir veri seti kullanılmıştır. Bu veri seti, sağlıklı ve farklı hastalıklara yakalanmış yaprakların görüntülerini içermektedir. Baireddy, bu görüntüleri analiz etmek ve hastalıkları sınıflandırmak için Evrişimli Sinir Ağları (CNN) kullanmıştır. Baireddy, tez çalışmasında model açıklanabilirliğini artırmak ve modelin hangi özelliklere göre karar verdiğini anlamak için yöntemler geliştirmiştir. Derin öğrenme modelleri genellikle "kara kutu" olarak adlandırılır, çünkü iç çalışma mekanizmalarını anlamak zordur. Baireddy, bu sorunu ele almak için Grad-CAM gibi görselleştirme tekniklerini kullanarak modelin hangi bölgelere odaklanarak karar verdiğini görselleştirmiştir. Çalışma sonucunda, derin öğrenme modellerinin bitki hastalıklarının tespiti ve sınıflandırılması için etkili bir şekilde kullanılabileceği gösterilmiştir. Geliştirilen modeller, yüksek doğruluk oranları ile bitki hastalıklarını tespit etmiş ve sınıflandırmıştır. Ayrıca, model açıklanabilirliğini artırmak için kullanılan yöntemler, modelin karar verme sürecini anlamamıza ve güvenilirliğini artırmamıza yardımcı olabilir. Baireddy'nin yüksek lisans tezi, derin öğrenme yöntemlerinin bitki hastalıklarının tespiti ve sınıflandırılması için önemli bir potansiyele sahip olduğunu göstermektedir.


Singh ve arkadaşları (2021) tarafından yapılan çalışmada, bitki stresinin tespiti için derin öğrenme yöntemlerini inceleyen bir derleme çalışmasıdır. Bitkiler, büyüme ve gelişme süreçleri boyunca çeşitli stres faktörlerine (biyotik ve abiyotik) maruz kalırlar. Bu stres faktörleri, bitki sağlığını ve verimliliğini olumsuz etkileyebilir. Bitki stresinin erken tespiti, zamanında müdahale edilmesini ve ürün kayıplarının en aza indirilmesini sağlayabilir. Geleneksel bitki stresi tespit yöntemleri, genellikle görsel incelemelere veya laboratuvar analizlerine dayanmaktadır. Ancak bu yöntemler, zaman alıcı, maliyetli ve uzmanlık gerektirebilir. Son yıllarda, derin öğrenme yöntemleri, bitki stresinin otomatik ve hızlı bir şekilde tespiti için umut verici bir alternatif olarak ortaya çıkmıştır. Singh ve arkadaşları, makalelerinde farklı bitki stres türleri (hastalık, besin eksikliği, su stresi,

tuzluluk stresi vb.) için kullanılan derin öğrenme modellerini ve elde edilen sonuçları incelemiştir. Ayrıca, derin öğrenme modellerinin performansını etkileyen faktörler (veri seti boyutu, görüntü kalitesi, model mimarisi vb.) ve gelecekteki araştırma yönleri hakkında da bilgi vermiştir. Derleme çalışması, derin öğrenme yöntemlerinin bitki stresi tespiti için etkili bir araç olabileceğini göstermektedir. Farklı CNN mimarileri (AlexNet, VGG, ResNet, Inception) ve transfer öğrenme gibi teknikler kullanılarak yüksek doğruluk oranları elde edilmiştir. Singh ve arkadaşlarının çalışması, derin öğrenme alanındaki araştırmacılar ve tarım uzmanları için bitki stresi tespiti konusunda kapsamlı bir kaynak sağlamaktadır.

3. MATERYAL VE YÖNTEM

3.1. Materyal

Bu çalışmada, bitki hastalıkları üzerine için yapılan analizlerde PlantVillage veri seti temel alınmıştır (www.kaggle.com/code/redpen12/cnn-disease-detection/input). Bu veri seti, Kaggle platformundan temin edilmiş olup, 224x224 piksel boyutunda renkli görüntülerden oluşmaktadır. Veri seti patates yapraklarından hastalık ve sağlıklı olma durumunu tanımak için kullanılan bir kıyaslama veri setidir. Veri seti erken yanıklık, geç yanıklık ve sağlıklı olmak üzere 3 farklı görüntü grubundan oluşmaktadır. Veri seti, görsel olarak birbirine yakın ve homojen olmayan 2152 adet görüntüden oluşmaktadır. Bu durum, sınıflandırma görevlerini zorlaştırıcı bir etkiye sahiptir. Bu görüntülerin erken yanıklık hastalığına sahip olan 1.000 görüntü, geç yanıklık hastalığına sahip olan 1.000 görüntü ve sağlıklı olan 152 görüntü bulunmaktadır. Veri setinden rastgele seçilmiş görüntüler Şekil 3.1’de verilmiştir.



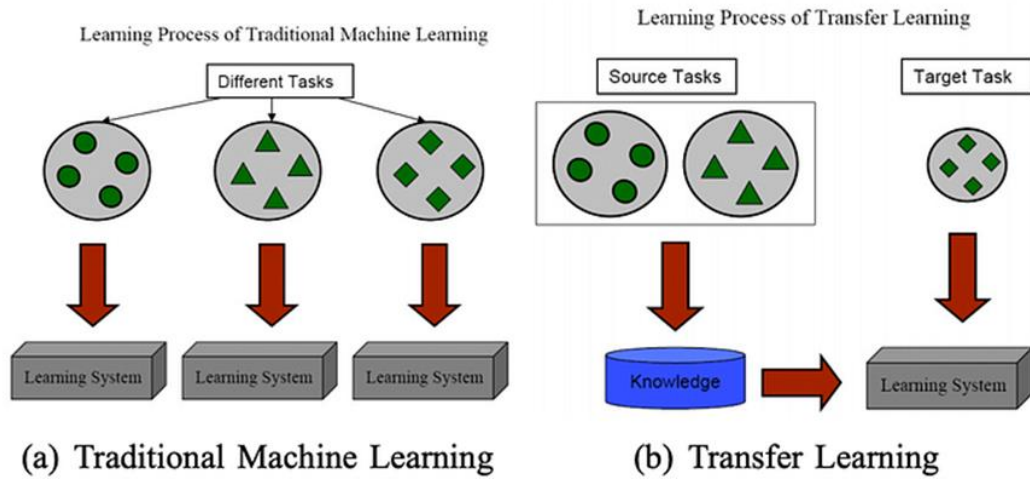
Şekil 3.1. Sağlıklı ve Hastalıklı Patates Yaprakları

3.2 Yöntemler

3.2.1. Transfer yöntemler

Transfer öğrenme, makine öğrenmesinde önceden öğrenilmiş bilgileri yeni görevlere aktararak öğrenme sürecini hızlandıran ve performansı artıran güçlü bir tekniktir. Bir alanda edinilen bilginin benzer bir alanda kullanılması prensibine dayanır.

Örneğin, görüntü sınıflandırma için eğitilmiş bir model, nesne tespiti gibi ilgili bir görev için ince ayar yapılarak kullanılabilir. Bu, özellikle veri kümelerinin sınırlı olduğu veya eğitim süresinin kısıtlı olduğu durumlarda büyük avantaj sağlar. Transfer öğrenmenin etkili olmasının nedenleri arasında veri verimliliği, hızlı öğrenme ve gelişmiş performans sayılabilir. Önceden eğitilmiş bir model, genel özellikleri zaten öğrenmiş olduğundan, yeni göreve özgü verilere daha az ihtiyaç duyar ve daha hızlı eğitilir. Ayrıca, kaynak görevden öğrendiği bilgileri genelleştirerek hedef görevde daha iyi sonuçlar elde edebilir. Şekil 3.2’de Transfer öğrenme ile makine öğrenmesi arasındaki farklılıklar gösterilmiştir.



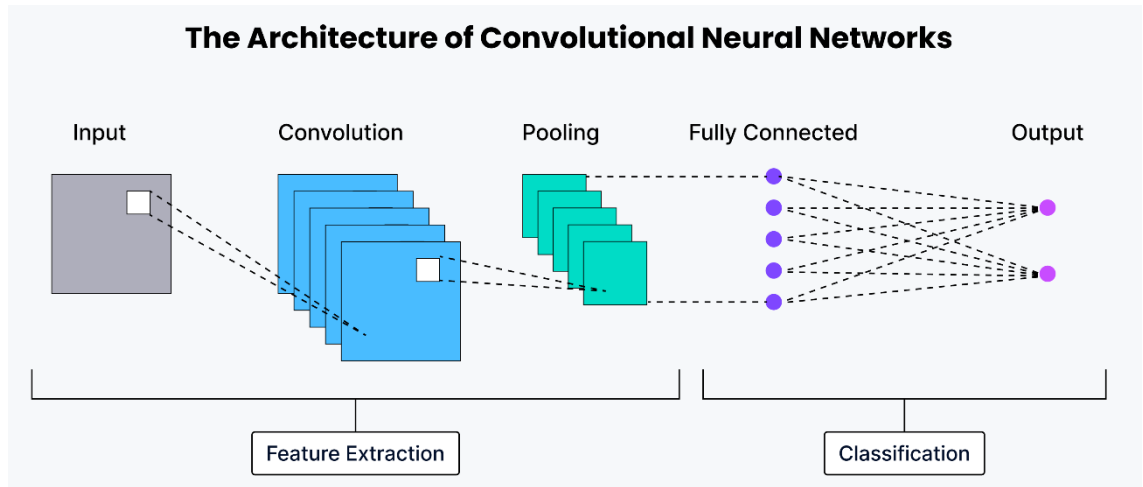
Şekil 3.2. Transfer öğrenme ile makine öğrenmesi arasındaki süreç farklılıkları (Pang & Yang, 2009)

Derin öğrenme modelleri, özellikle görüntü işleme, doğal dil işleme ve konuşma tanıma gibi alanlarda transfer öğrenmeden büyük ölçüde faydalanmaktadır. Örneğin, ImageNet gibi büyük bir veri kümesi üzerinde eğitilmiş bir CNN, tıbbi görüntü sınıflandırması gibi farklı bir görev için ince ayar yapılarak kullanılabilir. Transfer öğrenmenin başarısı için kaynak ve hedef görevler arasındaki benzerlik, kaynak veri kümesinin boyutu ve kalitesi ve model mimarisi gibi faktörler önemlidir. Transfer öğrenme sürecinde, hedef veri seti ile benzer özelliklere sahip bir kaynak veri seti seçmek, uygun bir önceden eğitilmiş model seçmek ve modeli hedef göreve uyarlamak için ince ayar yapmak önemlidir.

Sonuç olarak, transfer öğrenme, makine öğrenmesinde önemli bir paradigma değişikliğine yol açarak daha hızlı, daha verimli ve daha etkili öğrenme sağlar. Derin öğrenmedeki hızlı gelişmeler ve artan veri kullanılabilirliği ile transfer öğrenmenin önemi daha da artmaktadır.

3.2.2. Evrişimli sinir ağları (CNN)

Evrişimli sinir ağları (CNN), daha çok görüntü işleme ve veri sınıflandırmada büyük başarı gösteren güçlü derin öğrenme modelleridir. 1980'lerden beri temelleri atılmış olsa da, 1990'lardan sonra işlenmeye ve eğitime başlanmış ve 1995'te görüntü işleme uygulamalarında kullanılmaya başlanmıştır. CNN'ler, kendine has yapıları sayesinde görsel verilerdeki özellikleri etkili bir şekilde tanımlayarak üstün performans sağlarlar. Evrişimli Sinir Ağları (CNN'ler), görsel verilerin işlenmesinde yaygın olarak kullanılan bir derin öğrenme modelidir. Karmaşık yapıdaki görüntülerdeki desenleri ve özellikleri öğrenmek için tasarlanmıştır. CNN'ler, çekirdek adı verilen küçük filtreleri kullanarak girdi görüntüsünde kaydırma işlemi yapar ve bu sayede evrişim işlemi gerçekleştirir. Evrişim, havuzlama, tam bağlantı ve çıktı katmanları gibi ardışık katmanlardan oluşan CNN'ler, görüntüdeki önemli özellikleri çıkararak sınıflandırma, nesne tanıma ve benzeri görevlerde yüksek başarı sağlar. CNN'ler, görüntü işleme alanında devrim yaratan bir derin öğrenme modelidir. Bu modeller, görüntüleri oluşturan temel birimler olan pikseller arasındaki ilişkileri analiz ederek, daha yüksek seviyedeki anlamları çıkarır. CNN'ler, birbiri üzerine inşa edilmiş çok sayıda katmandan oluşur. Her katman, görüntünün farklı bir yönünü temsil eder. Örneğin, ilk katmanlar basit kenarları tespit ederken, daha sonraki katmanlar daha karmaşık şekilleri ve nesnelere tanımlar. CNN'lerin öğrenme süreci, geri yayılım algoritması sayesinde optimize edilir. Bu algoritma, ağın yaptığı hatalardan öğrenerek, daha doğru tahminler yapmasını sağlar. CNN ağının genel yapısı Şekil 3.3'te gösterilmektedir.



Şekil 3.3. CNN Ağının Genel Yapısı (Hidaka vd., 2017)

CNN'ler, bilgisayarların görüntüleri insan gibi anlamasını sağlayan güçlü bir araçtır. Bu ağlar, tıpkı bir insanın bir resmi incelerken belirli özelliklere (örneğin, bir yüzün gözleri, burnu ve ağzı) odaklanması gibi, görüntülerdeki önemli özellikleri belirler. Evrişim adı verilen bir işlem sayesinde, CNN'ler görüntülerdeki desenleri, dokuları ve şekilleri öğrenir. Bu sayede, nesnelere tanıma, sınıflandırma ve konumlarını belirleme gibi görevlerde kullanılırlar. Tıbbi görüntüleme hastalıkların teşhisi, otonom araçlarda çevre algısı gibi birçok alanda CNN'ler büyük başarılar elde etmiştir. CNN'ler genel olarak dört ana katmandan oluşmaktadır:

- **Evrişim Katmanı:** Veriler üzerinde belirginlikleri vurgular ve örüntülerin tanınmasını sağlar.
- **Havuzlama Katmanı:** Verileri özetleyerek boyutunu azaltır ve işlem süresini kısaltır.
- **Düzeltilme Katmanı:** Kayıpları azaltır ve veri eğitimini daha düzenli hale getirir.
- **Tam Bağlı Katmanı:** Modelin öğrenmiş olduğu tüm özellikleri sentezleyerek, nihai kararın verildiği sinir ağının son katmanıdır.

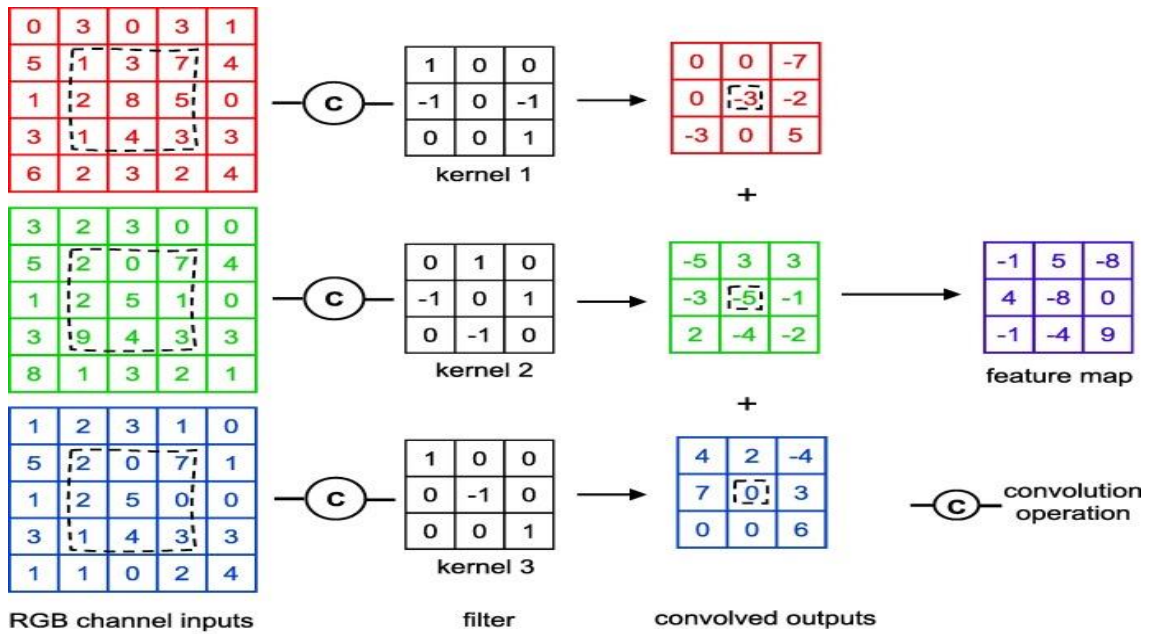
Bu katmanlar, CNN'lerin öğrenme sürecini destekleyerek karmaşık görsel verileri anlamlı hale getirir.

Giriş katmanı: CNN mimarisinde, giriş katmanı, verinin ham haliyle ağa beslendiği ve modelin veriyi işlemeye başladığı ilk noktadır. Modelin eğitimi ve öğrenme süreci için kritik öneme sahip olan bu katmanda, veri setini oluşturan temel veriler temsil edilir. Giriş katmanının yapısı ve veri düzenleme biçimi, modelin mimarisine bağlı olarak değişkenlik gösterir. Modelin veriyi etkili bir şekilde işleyebilmesi için girdi değerlerinin özenle seçilmesi ve düzenlenmesi gerekir. Bu, modelin performansını ve doğruluğunu doğrudan etkiler. Giriş katmanı, sadece verinin kabul edildiği bir nokta değil, aynı zamanda modelin veriyi ilk etkileşimini gerçekleştirdiği yerdir. Bu katmanda temsil edilen veriler, ağın geri kalanında gerçekleştirilecek işlemler için temel oluşturur. Giriş katmanı, CNN'lerin ayrılmaz bir parçası olup, modelin başarısını doğrudan etkiler.

Konvolüsyon katmanı: CNN'lerin görsel verileri anlamasını sağlayan en önemli bileşenlerden biri konvolüsyon katmanlarıdır. Bu katmanlar, özel filtreler sayesinde verideki önemli özellikleri öğrenir ve bu sayede modelin daha doğru tahminler yapmasına

olanak tanır. Bu filtreler, başlangıçta kenarlar, köşeler gibi temel geometrik özellikleri tanımlar. Daha sonraki konvolüsyon katmanları ise bu temel özellikler üzerine inşa ederek daha karmaşık özellikleri, örneğin nesnelerin şeklini ve boyutunu, öğrenir.

Konvolüsyon işlemi, girdi verileri üzerinde filtrelerin kaydırılması ve her konumda element bazında çarpım ve toplama işlemlerinin gerçekleştirilmesiyle elde edilen özellik matrislerini üretir. Bu özellik matrisleri, girdi verilerindeki önemli bilgileri vurgular ve CNN'in bu bilgileri öğrenmesini sağlar. CNN'lerin öğrenme sürecinin merkezinde konvolüsyon katmanları yer alır. Bu katmanlar, hataları düzelterek ve parametrelerini güncelleyerek, ağına daha karmaşık özellikleri öğrenmesini sağlar. Bu sayede CNN'ler, özellikle görüntü tanıma gibi görevlerde yüksek performans gösterir.



Şekil 3.4. Evrişim katmanı özellik çıkarımı (Kuchera & Malina, 2019)

Evrişim süreci, yukarıdaki Şekil 3.4'te gösterildiği gibi, bir filtre ve girdi verisi arasındaki etkileşimle gerçekleşir. Bir örnekle açıklamak gerekirse, 5x5 boyutunda bir girdi matrisimiz olduğunu düşünelim. Bu matrisin üzerine 3x3 boyutunda bir filtre yerleştirerek, bu filtreyi matris üzerinde kaydırırız. Her kaydırma işleminde, filtre ve altındaki matris elemanları çarpılarak elde edilen sonuçlar toplanır. Bu işlem, tüm matris üzerinde tekrarlanarak bir özellik haritası oluşturulur. Bu harita, görüntünün belirli özelliklerini (örneğin, dikey veya yatay çizgiler) temsil eder. Bu özellik haritası, görüntüdeki farklı özellikleri temsil eden ağırlık değerlerini içerir. Örneğin, kenarlar, köşeler, renk değişimleri gibi görsel özellikler bu şekilde yakalanır. Evrişim katmanları,

bu özellikleri öğrenerek ve birleştirerek derin öğrenme ağlarının karmaşık görsel tanıma görevlerini (nesne tespiti, görüntü sınıflandırma vb.) başarıyla gerçekleştirmesini sağlar.


Aktivasyon katmanı: Aktivasyon fonksiyonları, sinir ağlarının temel yapı taşları olan nöronların giriş sinyallerini düzenleyen ve ağın öğrenme yeteneğini belirleyen kritik bileşenlerdir. Bu fonksiyonlar, nöronların çıkışlarını belirli aralıklara sıkıştırarak, ağın daha verimli çalışmasını sağlar. Sigmoid, ReLU, Hiperbolik Tanjant gibi çeşitli aktivasyon fonksiyonları, problemin doğasına göre seçilir ve nöronların etkinleştirilip etkinleştirilmediğini kontrol ederek, ağın bilgi işleme sürecini yönlendirir. Özellikle görüntü işleme gibi matris işlemlerinin yoğun olduğu alanlarda hassas bir aktivasyon fonksiyonu kullanmak önemlidir. Aksi takdirde öğrenme hızı düşebilir. Doğrusal aktivasyon fonksiyonu, sabit bir çıktı değeri ürettiği için geri yayılım sırasında hata oranı da sabit kalır. Bu durum, istenen çıktının elde edilmesini zorlaştırır ve geri yayılım algoritmasının etkinliğini azaltır. Bu fonksiyonun matematiksel ifadesi, Denklem 3.1'de sunulmuştur. Bu denklemdaki "a" parametresi, kullanıcı tarafından belirlenen bir sabit değerdir ve fonksiyonun davranışını etkiler. Bu parametre seçimi, problemin özelliğine göre değişebilir (Arslan, 2022, s. 39-41).

$$f(x) = ax \quad (3.1)$$

Sigmoid fonksiyonu, S harfine benzeyen karakteristik bir eğriye sahip, doğrusal olmayan bir matematiksel işlemdir. Yapay sinir ağlarında sıklıkla tercih edilen sigmoid, herhangi bir sayısal girdiyi 0 ile 1 arasında bir değere dönüştürerek, bir olayın gerçekleşme olasılığı gibi yorumlanabilecek bir çıktı üretir. Bu özelliği, özellikle iki sınıflı (örneğin, evet/hayır, kedi/köpek) sınıflandırma problemlerinde tercih edilmesini sağlar.

Sigmoid fonksiyonu, ağa nonlineerlik katarak karmaşık ilişkileri öğrenme yeteneğini artırır. 0 ile 1 arasındaki çıktı değerleri, olasılık yorumlamasına olanak tanır. Ayrıca, türevlenebilir olması, gradyan tabanlı optimizasyon algoritmalarının kullanılmasını mümkün kılar. Şekil 3.5'te Sigmoid aktivasyon fonksiyonunun türevlenebilen bir aktivasyon fonksiyonu olduğu gösterilmektedir. Bu fonksiyonun matematiksel karşılığı denklem 3.2'de gösterilmektedir. Bundan dolayı öğrenme işlemi daha hızlı ve etkili gerçekleştirilebilmektedir.


$$f_{sigm}(x) = 1 / (1 + e^{-x}) \quad (3.2)$$



Şekil 3.5. Sigmoid aktivasyon fonksiyonu ve türevi

Hiperbolik Tanjant (Tanh): Hiperbolik tanjant (tanh) fonksiyonu, -1 ile 1 arasında değerler veren, 0 merkezli simetrik bir S eğrisi şeklinde grafikleştirilen bir aktivasyon fonksiyonudur. Bu fonksiyon, sigmoid fonksiyona benzer şekilde çalışır ancak çıktı aralığı daha geniştir. [-1, +1] aralığındaki çıktı değerleri, özellikle ikili sınıflandırma problemlerinde avantaj sağlar. Tanh fonksiyonu, sinir ağlarının daha hızlı öğrenmesini sağlayarak, modelin performansını artırır. Bu özelliği, onu birçok derin öğrenme uygulamasında popüler bir aktivasyon fonksiyonu haline getirir. Şekil 3.6'da Hiperbolik tanjant fonksiyonu ve bu fonksiyonun türevlenebilir olduğu gösterilmektedir. Bu fonksiyonun matematiksel karşılığı denklem 3.3'te gösterilmektedir.

$$f(x)\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.3)$$




Şekil 3.6. Tanh aktivasyon fonksiyonu ve türevi

ReLU: ReLU, basitçe ifade etmek gerekirse, pozitif girdiler için kendisini, negatif girdiler için ise sıfırı döndüren bir fonksiyondur. Matematiksel olarak Denklem 3.4'te gösterilmiştir.

$$\text{ReLU}(x) = f(x) = \max(0, x) \quad (3.4)$$


Bu basit yapısına rağmen, ReLU, birçok derin öğrenme modelinde tercih edilmesinin başlıca nedeni bu fonksiyon ile türevi hesaplamak oldukça kolaydır. Bu durum, geri yayılım algoritması gibi optimizasyon yöntemlerinin daha hızlı ve verimli çalışmasını sağlar. ReLU, negatif girdiler için sıfır çıktısı ürettiği için, ağıdaki birçok nöronun sıfır çıktı üretmesine neden olabilir. Bu durum, ağı daha seyrek hale getirerek, overfitting probleminin azalmasına yardımcı olur. Sigmoid ve tanh gibi diğer aktivasyon fonksiyonlarında görülen vanishing gradient problemi, derin ağlarda öğrenmeyi zorlaştırır. ReLU ise bu sorunu büyük ölçüde çözer. Şekil 3.7’de ReLU fonksiyonu ile bu fonksiyonun türevi gösterilmektedir.



Şekil 3.7. ReLU aktivasyonu fonksiyonu ve bu fonksiyonun türevi

Leaky ReLU: Leaky ReLU, ReLU fonksiyonunun bir varyasyonu olup, negatif girdilere karşı daha duyarlı bir davranış sergiler. ReLU, negatif girdilerde sıfır çıktısı ürettiği için bazı nöronlar eğitim sürecinde hiç aktive olmayabilir (ölü nöron problemi). Leaky ReLU ise negatif girdiler için küçük bir eğime sahip olduğundan, bu nöronların tamamen susmasını engeller. Bu sayede ağ, daha geniş bir veri yelpazesine duyarlı hale gelir ve öğrenme performansı artar. Bu fonksiyonun matematiksel karşılığı denklem 3.5’te gösterilmektedir

$$f(x)_{\text{LeakyReLU}(x)} = f(x) \begin{cases} x, & x \geq 0 \\ mx, & x \leq 0 \end{cases} \quad (3.5)$$



Şekil 3.8. Leaky ReLU aktivasyonu fonksiyonu ve bu fonksiyonun türevi

Swish Aktivasyon Fonksiyonu: Swish (A Self-Gated) aktivasyon fonksiyonu, geleneksel aktivasyon fonksiyonlarından farklı olarak, hem pozitif hem de negatif girdi değerleri için doğrusal olmayan bir çıktı üretebilen bir fonksiyondur. Bu özelliği sayesinde, Swish, derin öğrenme modellerinde daha esnek bir yapı sunar. Özellikle girdi değerlerinin geniş bir aralıkta değiştiği durumlarda ve rekürrent sinir ağları gibi modellerde etkili sonuçlar verir. Swish, girdi değerleri arttıkça çıktının da artma eğiliminde olması sayesinde, öğrenme sürecinde daha hızlı ve daha iyi sonuçlar elde edilmesini sağlar. Bu fonksiyonun matematiksel karşılığı denklem 3.6'da gösterilmektedir


$$f(x)_{Swish} = 2x\sigma(\beta x) = \begin{cases} \beta = 0 \text{ için} & f(x) = x \\ \beta \rightarrow \infty \text{ için} & f(x) = 2\max(0, x) \end{cases} \quad (3.6)$$

Havuzlama katmanı: Havuzlama katmanı, CNN'lerde veri boyutunu azaltarak ağırlık sayısını ve hesaplama maliyetini düşüren önemli bir bileşendir. Bu katman, öğrenme sürecini hızlandırırken aynı zamanda modelin genelleme yeteneğini de artırabilir. Havuzlama katmanında herhangi bir öğrenme gerçekleşmez; bu katmanın amacı, evrişim katmanından gelen özellik haritalarını özetlemek ve önemli bilgileri koruyarak boyutlarını küçültmektir. Bu sayede eğitim süresi kısalmış, böylelikle zamandan ve kaynaklardan tasarruf sağlanır.

Havuzlama işlemleri genellikle birbirinden farklı iki yöntemle gerçekleştirilir:

- **Ortalama havuzlama:** Uygulanacak olan filtrenin kapsadığı alandaki değerlerin ortalaması alınır.
- **Maksimum havuzlama:** Filtre içindeki en büyük değer seçilir.

Bu yöntemler, veri işleme ve sinyal analizi gibi birçok alanda yaygın olarak kullanılır. Örneğin, 2x2 boyutunda bir maksimum havuzlama katmanı, görüntü matrislerindeki her 2x2'lik bloğun maksimum değerini alarak boyutun küçülmesini ve işlem maliyetinin azaltılmasını sağlar. Havuzlama işlemi sırasında "kaydırma" (stride) parametresi, filtrenin girdi verisinin üzerinde ne kadar birim kaydırılacağını belirlemektedir. Havuzlama katmanına bağlı olan boyutu da buradaki işlemi kontrol etmede çok önemlidir. Havuzlama katmanı özetle derin öğrenme ağlarının işlemsel hızlarını artırırken aynı anda öğrenmeyi gerçekleştirilerek verinin önemli özelliklerini vurgular ve modelin genelleme yeteneğini artırır.

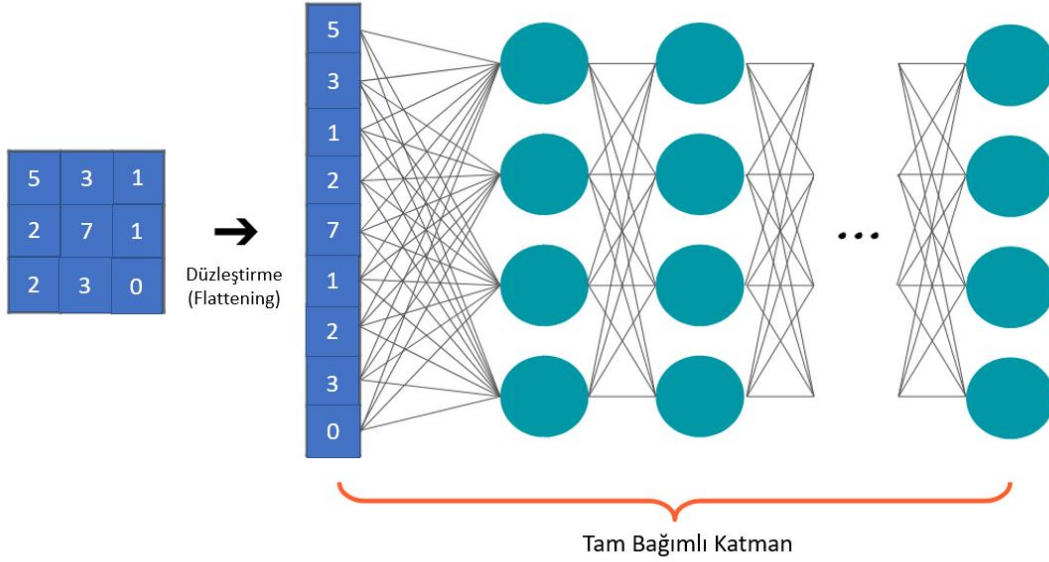


Şekil 3.9 2x2 Maksimum havuzlama ve ortalama havuzlama (Yani vd., 2019)

Şekil 3.9'da maksimum havuzlama ile ortalama havuzlama yöntemlerini göstermektedir. Maksimum havuzlamada, veri matrisine 2x2 boyutunda bir filtre uygulanır ve her bölgedeki en büyük değer seçilerek yeni ve daha küçük bir matris oluşturulur. Bu yöntem, veri boyutunu küçültürken önemli bilgilerin korunmasına yardımcı olur. Ortalama havuzlamada ise, yine 2x2 boyutunda bir filtre kullanılır, ancak bu kez her bölgedeki değerlerin ortalaması alınarak yeni matris oluşturulur. Bu yöntem, verinin genel özelliklerini daha iyi temsil edebilir. Her iki yöntem de veri boyutunu küçültürken işlem yükünü azaltır ve modelin daha hızlı çalışmasını sağlar. Hangi yöntemin daha uygun olduğu, verinin özelliklerine ve modelin amacına bağlı olarak değişebilir.

Tam Bağlantılı Katman (FC): Tam bağlantılı katmanlar, CNN'lerde evrişim ve havuzlama katmanlarından sonra gelir. Evrişim katmanları, girdi görüntüsünde önemli özellikleri çıkarır. Havuzlama katmanları ise bu özelliklerin boyutunu küçültür ve ağına daha az hesaplama yapmasını sağlar.


Tam bağlantılı katmanlar, düzleştirilmiş özellik haritalarını alır ve bunları sınıflandırma için kullanır. Her bir nöron, girdideki her bir özellikle bağlantılıdır. Bu bağlantılar, ağız öğrenme sürecinde ayarlanan ağırlıklara sahiptir. Şekil 3.10'da tam bağlantılı katmana ait görsel bulunmaktadır.



Şekil 3.10. Tam bağlantı katmanı

Son tam bağlantılı katman, genellikle sınıf sayısı kadar nörona sahiptir ve her sınıf için bir olasılık değeri üretir. Bu katmanda genellikle aktivasyon fonksiyonu kullanılmaz.


Dropout Katmanı: Dropout katmanı, derin öğrenme modellerinde aşırı öğrenmeyi (overfitting) önlemek için kullanılan bir düzenleme (regularization) tekniğidir. Aşırı öğrenme, modelin eğitim verilerindeki örüntüleri ezberlemesi ve yeni, görünmeyen verilere genelleme yapamaması durumudur. Şekil 3.11'de rastgele bazı düğümleri ile silinen ağa ait görsel verilmiştir. Dropout katmanı en önemli gerekliliği aşırı öğrenmeyi engellemesidir.



Şekil 3.11. Örnek bir Dropout Katmanı

Dropout, eğitim sırasında her iterasyonda rastgele seçilen nöronları ağdan geçici olarak çıkararak çalışır. Bu, nöronların birbirine çok fazla bağımlı olmasını ve eğitim verilerindeki gürültüyü ezberlemesini engeller. Her iterasyonda farklı bir nöron alt kümesi aktif olacağından, model daha robust ve genelleme yeteneği yüksek hale gelir.

Düzleştirme Katmanı: CNN'lerde, görsel veriler, evrişim ve havuzlama işlemleriyle işlenir. Sonuç olarak elde edilen özellik haritaları, birleştirilerek ve düzleştirilerek, tam bağlantılı katmana giriş olarak verilir. Bu sayede, görüntüdeki yüksek boyutlu bilgi, daha düşük boyutlu bir vektörde temsil edilir ve sınıflandırma gibi görevler için kullanılabilir (Doğan & Türkoğlu, 2018).




Şekil 3.12. Düzleştirme katmanı

Şekil 3.12'de, havuzlama katmanından elde edilen özellik haritası düzleştirilerek tek boyutlu bir vektör haline getirilir. Bu vektör, tam bağlantılı katmana giriş olarak verilir ve istenen çıktı boyutuna dönüştürülür. Sınıflandırma problemlerinde, çıktı boyutu genellikle sınıf sayısına eşittir.

3.2.2.1. ResNet18

ResNet-18, Microsoft Research tarafından 2015 yılında geliştirilen bir derin öğrenme modelidir ve Evrişimli Sinir Ağları (CNN) mimarisine dayanır. Özellikle ImageNet veri seti üzerinde yapılan görüntü sınıflandırma ve nesne tespiti görevlerinde önemli başarılar elde etmiştir. ResNet-18, "artık öğrenme" (residual learning) prensibine dayanır. Geleneksel derin sinir ağlarında, her katman bir önceki katmanın çıktısını alır ve işler. Bu yapı, derin ağlarda "gradyan kaybolması" (vanishing gradient) sorununa yol açabilir. Gradyan kaybolması, ağın alt katmanlarındaki ağırlıkların güncellenmesini zorlaştırır ve öğrenme sürecini yavaşlatır. ResNet, bu sorunu çözmek için "atlama bağlantıları" veya "rezidüel bağlantılar" kullanır. Bu bağlantılar, bir katmanın çıktısını, birkaç katman sonrasına doğrudan iletir. Böylece, gradyanlar ağı tüm katmanlarına daha etkili bir şekilde yayılabilir ve derin ağların eğitimi daha kolay hale gelir. ResNet-18, adından da anlaşılacağı gibi 18 katmandan oluşur. Bu katmanlar, evrişimli katmanlar, toplu normalleştirme (batch normalization) katmanları ve ReLU aktivasyon fonksiyonlarından oluşur. Her artık blok, iki veya üç evrişimli katman içerir. ResNet-18, görüntü sınıflandırma, nesne tespiti ve görüntü segmentasyonu gibi çeşitli görevlerde kullanılabilir. Ayrıca, transfer öğrenme için de sıklıkla tercih edilir. Transfer öğrenme, önceden eğitilmiş bir modelin ağırlıklarını kullanarak yeni bir görevi öğrenmek için kullanılan bir tekniktir. ResNet-18'in hızlı eğitilebilir olması ve iyi performans göstermesi, onu birçok uygulama için popüler bir model haline getirmiştir. Ayrıca, ResNet-50, ResNet-101 ve ResNet-152 gibi daha büyük ve daha derin ResNet varyantlarının geliştirilmesinin de temelini oluşturmuştur. Şekil 3.13'te ResNet-18 modelinin örneleştirilmiş temel yapısı görülmektedir.




Şekil 3.13. ResNet-18 modeli

He ve arkadaşları, 2016 yılında derin öğrenme alanında önemli bir model olan ResNet'i (Residual Network) geliştirdiler (Sarwindaa, Paradisaa, & Alhadi , 2021, s. 424-427). Bu çalışmaya, derin öğrenme eğitiminde karşılaşılan bazı zorluklar sebep oldu. Özellikle derin ağların eğitimi sırasında ortaya çıkan problemler, He ve ekibini ResNet mimarisini oluşturmaya yöneltti. Derin öğrenme modelleri genellikle çok sayıda katman içerir ve bu katmanların eğitimi uzun zaman alabilir. Ayrıca, katman sayısı arttıkça modelin performansında düşüş gözlemlenebilir. ResNet, bu sorunları ele almak için "atlama bağlantıları" veya "kısa yollar" kullanır. Bu bağlantılar, ağın çok daha hızlı ve daha etkili şekilde eğitilmesini sağlar. ResNet'in en önemli avantajlarından biri, ağ derinleştikçe performansın azalmamasıdır. Bu özellik, ResNet'i diğer derin öğrenme mimarilerinden ayırır. Ayrıca, ResNet ağları daha kolay eğitilebilir ve hesaplama açısından daha verimlidir. ResNet mimarisi, ReLU aktivasyon fonksiyonu ve toplu normalizasyon içeren iki veya üç katmanlı bloklar halinde uygulanır. Bu bloklar, atlama bağlantıları ile birbirine bağlanır. ResNet, görüntü sınıflandırma gibi görevlerde daha önce kullanılan modellere göre daha iyi sonuçlar elde etmiştir. Bu başarı, ResNet'in görüntü özelliklerini etkili bir şekilde öğrenme yeteneğinden kaynaklanmaktadır. ResNet'te, giriş ve çıkış katmanları arasında birden fazla katman eklenerek atıllı öğrenme gerçekleştirilir. Atıllı bloklar, giriş ve çıkış veri boyutları aynı olduğunda etkili olur. Her ResNet bloğu, ResNet-18 ve ResNet-34 gibi daha küçük ağlar için iki katman, ResNet-50 ve ResNet-101 gibi daha büyük ağlar için ise üç katman içerir.

3.2.2.2. ResNET50

ResNet-50'nin başarısının arkasında yatan temel etken, artık öğrenme (residual learning) prensibidir. Geleneksel derin sinir ağlarında, her katman bir önceki katmanın çıktısını alır ve işler. Ancak, ağ derinleştikçe, "gradyan kaybolması" sorunu ortaya çıkabilir. Bu, ağın alt katmanlarındaki ağırlıkların güncellenmesini zorlaştırır ve öğrenme sürecini yavaşlatır. ResNet, bu sorunu çözmek için atlama bağlantıları veya rezidüel bağlantılar kullanır. Bu bağlantılar, bir katmanın girdisini, birkaç katman sonrasında doğrudan iletir. Böylece, gradyanlar ağın tüm katmanlarına daha etkili bir şekilde yayılabilir ve derin ağların eğitimi daha kolay hale gelir. ResNet-50, adından da anlaşılacağı gibi 50 katmandan oluşur. Bu katmanlar, evrişimli katmanlar, toplu normalleştirme katmanları ve ReLU aktivasyon fonksiyonlarından meydana gelir. Her artık blok, üç evrişimli katman içerir. ResNet-50 artık bağlantılar sayesinde, derin ağlarda gradyan kaybolması sorunu azaltılır ve eğitim daha etkili hale gelir. ResNet-50 mimarisi, daha derin ağların eğitilmesini ve daha yüksek performans elde edilmesini mümkün kılmasının yanı sıra birçok görüntü işleme görevinde son teknoloji doğruluk oranları elde eder. Ayrıca önceden eğitilmiş ağırlıkları kullanılarak transfer öğrenme için de sıklıkla tercih edilir. ResNet-50 görüntü sınıflandırma, nesne tespiti, yüz tanıma ve görüntü segmentasyonu gibi birçok alanda da kullanılır. He ve arkadaşları (2016), ResNet mimarisini tanıttıkları makalelerinde, "Derin artık ağların, doğruluk ve yakınsama açısından daha önceki ağlardan önemli ölçüde daha iyi performans gösterdiğini gözlemledik" şeklinde belirtmişlerdir. Bu, ResNet-50'nin derin öğrenme alanına getirdiği önemli katkılardan birini vurgular. ResNet-50, derin öğrenme ve bilgisayarla görme alanında önemli bir modeldir. Görüntü tanıma alanında elde ettiği başarılar ve sunduğu avantajlar, onu birçok uygulama için popüler bir seçenek haline getirmiştir.



Şekil 3.14. ResNet-50 mimarisi (Gomes vd., 2022)

Şekil 3.14' de ResNet-50'nin yapısını bir şema olarak gösterilmiştir. Bu şemaya göre resimde gösterilen adımlar ve bileşenler şöyle açıklanabilir:

1. **Input:** İşlenecek girdi görüntüsü.
2. **Zero Padding:** Girdi görüntüsünün kenarlarına sıfırlar eklenir. Bu, evrişim işlemi sonrasında çıktı boyutunun küçülmesini engeller ve kenar bilgilerinin korunmasına yardımcı olur.
3. **CONV:** Evrişim katmanı. Öğrenilen filtreler, girdi görüntüsü üzerinde kaydırılarak özellikler çıkarılır.
4. **Batch Norm:** Toplu normalleştirme katmanı. Her bir katmanın çıktılarını normalize eder, eğitimi hızlandırır ve modelin genelleme yeteneğini artırır.
5. **ReLU:** ReLU aktivasyon fonksiyonu. Doğrusal olmayanlık ekler ve ağıın daha karmaşık örüntüleri öğrenmesini sağlar.
6. **MaxPool:** Maksimum havuzlama katmanı. Özellik haritalarının boyutunu küçültür, hesaplama maliyetini azaltır ve ağıın özniteliklere olan konum hassasiyetini azaltır.
7. **Conv Block:** Evrişim blokları. Birkaç evrişim katmanını, toplu normalleştirme katmanlarını ve ReLU aktivasyon fonksiyonlarını içerir. ResNet-50'de her evrişim bloğu üç evrişim katmanından oluşur.
8. **ID Block:** Kimlik blokları (Identity blocks). Evrişim bloklarına benzer, ancak atlama bağlantıları (shortcut connections) içerir. Bu bağlantılar, bir katmanın girdisini, birkaç katman sonrasında doğrudan iletir. Böylece, gradyanlar ağıın tüm katmanlarına daha etkili bir şekilde yayılabilir ve derin ağların eğitimi daha kolay hale gelir.

9. x3, x4, x6: Her aşamada (stage) bulunan blok sayısını gösterir. Örneğin, Stage 2'de 4 adet blok bulunur.

10. 1x1, 3x3, ... , 2048: Evrişim katmanlarında kullanılan filtre boyutlarını ve filtre sayısını gösterir. Örneğin, "1x1, 64" ifadesi, 1x1 boyutunda 64 filtre kullanıldığını belirtir.

11. Avg Pool: Ortalama havuzlama katmanı. Özellik haritasının ortalama değerini hesaplayarak boyutunu küçültür.

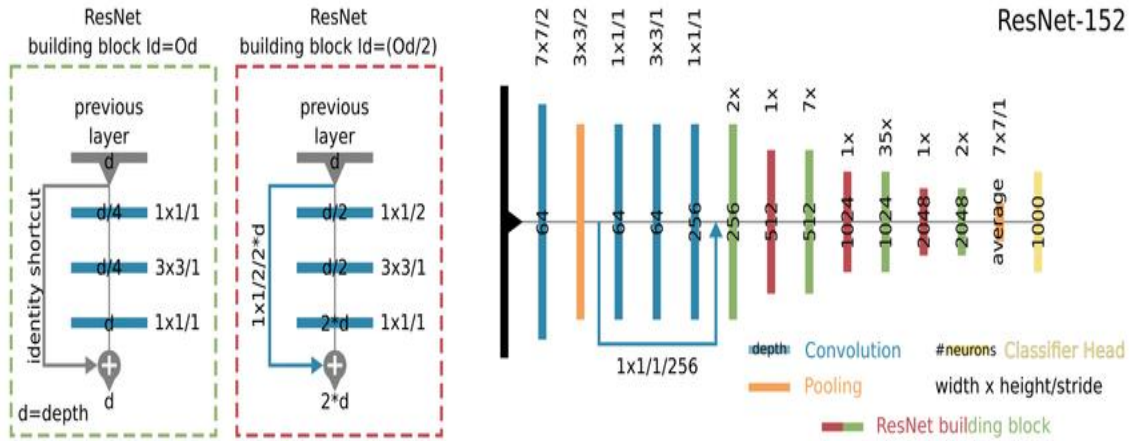
12. Flattening: Düzleştirme. Çok boyutlu bir diziyi (özellik haritası) tek boyutlu bir vektöre dönüştürür.

13. FC: Tam bağlantılı katman. Düzleştirilmiş özellik vektörünü alır ve sınıflandırmalar için kullanır.

ResNet'in en önemli özelliği olan atlama bağlantıları (identity), resimde sol üst köşedeki kutucuk içinde gösterilmiştir. Bu bağlantılar, bir katmanın girdisini, birkaç katman sonrasına doğrudan ileterek gradyan kaybolması sorununu azaltır ve derin ağların eğitimini kolaylaştırır. ResNet-50, bu mimarinin 50 katmanlı bir versiyonudur ve görüntü tanıma alanında yaygın olarak kullanılan güçlü bir modeldir.

3.2.2.3 ResNet 152

ResNet-152, 2015 yılında Microsoft Research tarafından tanıtılan ve derin öğrenme alanında, özellikle görüntü tanıma görevlerinde önemli bir etkiye sahip olan bir evrişimli sinir ağı (CNN) modelidir. Adından da anlaşılacağı gibi, 152 katmana sahip oldukça derin bir ağıdır. Bu derinlik, ResNet-152'nin karmaşık desenleri öğrenmesini ve yüksek doğruluk oranları elde etmesini sağlar. ResNet-152, temelde ResNet mimarisinin bir varyasyonudur ve artık öğrenme (residual learning) prensibine dayanır. Bu prensip, ağa atlama bağlantıları veya rezidüel bağlantılar ekleyerek derin ağlardaki "gradyan kaybolması" sorununu ele alır. Gradyan kaybolması, ağın alt katmanlarındaki ağırlıkların güncellenmesini zorlaştıran bir sorundur ve derin ağların eğitimini olumsuz etkiler. ResNet mimarisindeki atlama bağlantıları, bir katmanın girdisini, birkaç katman sonrasına doğrudan iletir. Bu, gradyanların ağın tüm katmanlarına daha etkili bir şekilde yayılmasını sağlar ve derin ağların başarılı bir şekilde eğitilmesini mümkün kılar. Şekil 3.15'te ResNet152 modelinin genel yapısı görülmektedir.



Şekil 3.15. ResNet-152 mimarisi (Hoeser vd., 2020)

ResNet-152'nin Öne Çıkan Özellikleri:

Derin Mimari: 152 katmanlı yapısı, karmaşık özellikleri öğrenme ve yüksek doğruluk elde etme kapasitesi sağlar.

Artık Öğrenme: Atlama bağlantıları sayesinde gradyan kaybolması sorunu azaltılır ve derin ağların eğitimi kolaylaşır.

Yüksek Performans: Görüntü sınıflandırma, nesne tespiti ve diğer görüntü tanıma görevlerinde son teknoloji doğruluk oranları elde eder.

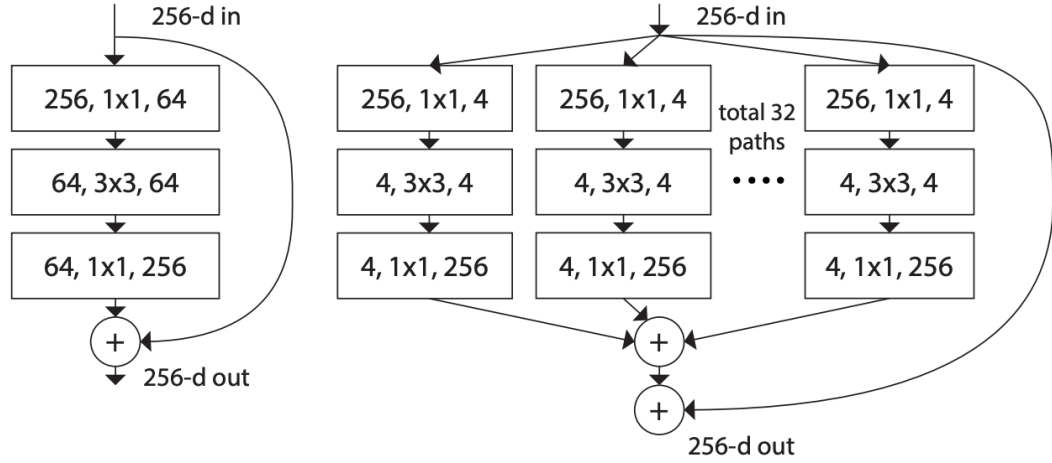
Transfer Öğrenme: Önceden eğitilmiş ağırlıkları, farklı görevler için transfer öğrenmede kullanılabilir.

"Derin ResNet modelleri, özellikle ResNet-152 gibi varyantlar, tıbbi görüntü analizinde yaygın olarak kullanılmaktadır. Bu modellerin karmaşık özellikleri öğrenme yeteneği, hastalık teşhisi ve tedavi planlamasında önemli bir rol oynamaktadır." - **Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2021)**. ResNet-152, yüksek doğruluk gereksinimleri olan ve hesaplama kaynaklarının yeterli olduğu uygulamalar için ideal bir seçimdir. Özellikle görüntü sınıflandırma, nesne tespiti, tıbbi görüntü analizi ve robotik gibi alanlarda kullanılmaktadır. Sonuç olarak, ResNet-152, derin öğrenme alanında önemli bir modeldir ve derin mimarisi sayesinde karmaşık problemleri çözmek ve yüksek doğruluk oranları elde etmek için güçlü bir araçtır.

3.2.2.4. ResNext

ResNeXt, 2016 yılında Facebook AI Research tarafından geliştirilen ve derin öğrenme alanında, özellikle görüntü tanıma görevlerinde önemli bir etkiye sahip olan bir evrişimli sinir ağı (CNN) modelidir. ResNet mimarisinin bir uzantısı olan ResNeXt,

"gruplanmış evrişimler" (grouped convolutions) adı verilen bir teknik kullanarak ağıın öğrenme kapasitesini ve performansını artırır. ResNeXt'in temel fikri, bir evrişim katmanını, daha küçük filtrelere sahip birden fazla "grup"a bölmektir. Her grup, girdi kanallarının bir alt kümesi üzerinde çalışır ve kendi filtrelerini öğrenir. Grupların çıktıları daha sonra birleştirilerek sonuç elde edilir. Bu yaklaşım, ağıın daha fazla özellik öğrenmesini ve daha esnek olmasını sağlar.



Şekil 3.16. Resnet ile ResNext mimarilerini karşılaştırılması

Şekil 3.16'da görüldüğü üzere soldaki ResNet bloğu, ardışık evrişim katmanlarını kullanırken, sağdaki ResNeXt bloğu aynı işlemi 32 paralel dala bölerek gerçekleştirir. Bu "gruplanmış evrişim" yaklaşımı, ResNeXt'in daha az parametreyle daha zengin özellikler öğrenmesini sağlar. Her iki blok da atlama bağlantıları kullanarak derin ağlarda gradyan kaybolması sorununu ele alırlar.

ResNeXt'in Öne Çıkan Özellikleri:

Gruplanmış Evrişimler: Ağıın öğrenme kapasitesini ve performansını artırır.

Modüler Yapı: Ağıın farklı bloklar halinde tasarlanması, anlaşılmasını ve değiştirilmesini kolaylaştırır.

Yüksek Doğruluk: Görüntü sınıflandırma, nesne tespiti ve diğer görüntü tanıma görevlerinde son teknoloji doğruluk oranları elde eder.

Verimlilik: ResNet'e kıyasla daha az parametre kullanarak benzer veya daha iyi performans elde edebilir.

Xie ve arkadaşları (2017), ResNeXt mimarisini tanıttıkları makalelerinde, "ResNeXt'in, ImageNet veri seti üzerinde yapılan görüntü sınıflandırma görevlerinde, ResNet'e göre daha yüksek doğruluk oranları elde ettiğini ve daha az parametre kullandığını" belirtmişlerdir. Bu, ResNeXt'in derin öğrenme alanına getirdiği önemli katkılardan birini

vurgular. ResNeXt, görüntü tanıma, doğal dil işleme ve diğer derin öğrenme uygulamalarında başarıyla kullanılmaktadır. Modüler yapısı ve yüksek performansı, onu birçok araştırmacı ve uygulama geliştirici için çekici bir seçenek haline getirmektedir.

3.2.3 Performans Ölçütleri

Yapay zekâ, veri madenciliği ve özellikle derin öğrenme alanlarında karşılaşılan problemlerin çözümünde kullanılan modellerin performansını ve başarısını değerlendirmek için çeşitli ölçütler mevcuttur. Derin öğrenme kapsamında, özellikle sınıflandırma problemlerinde kullanılan modellerin performansını ölçmek ve karşılaştırmak için farklı metrikler kullanılır. Bu metrikler, modelin tahmin ettiği değerler ile gerçek değerler arasındaki uyumu ölçer ve modelin başarısını değerlendirmede önemli bir rol oynar. Her metriğin kendine özgü avantajları ve dezavantajları vardır ve bir modelin performansı farklı metriklere göre değişiklik gösterebilir. Örneğin, bir model doğruluk (accuracy) metriğinde yüksek bir değer elde ederken, hassasiyet (precision) veya geri çağırma (recall) metriklerinde daha düşük performans gösterebilir. Bu nedenle, modelin performansını değerlendirirken birden fazla metriği dikkate almak önemlidir. Ayrıca, modelin başarısı sadece kullanılan metriklere değil, aynı zamanda eğitim ve test verilerinin nasıl bölündüğüne ve sınıflandırma problemindeki sınıfların dağılımına da bağlıdır. Dengesiz veri setlerinde, bazı sınıflar diğerlerinden daha fazla temsil edilir ve bu durum, modelin performansını ve değerlendirme metriklerini etkileyebilir. Bu tez çalışmasında, derin öğrenme modellerinin performansını değerlendirmek için bir dizi metrik kullanılmıştır. Bu metrikler, modelin sınıflandırma yeteneğini, tahminlerinin doğruluğunu ve genel başarısını ölçmek için kullanılacaktır. Metriklerin detaylı açıklamaları ve formülleri ilerleyen bölümlerde sunulacaktır. Özetle, derin öğrenme modellerinin performansını değerlendirmek için birden fazla metrik kullanılır ve modelin başarısı, bu metriklerin yanı sıra veri setinin özelliklerine ve sınıf dağılımına da bağlıdır.

3.2.3.1. Karışıklık Matrisi

Karışıklık matrisi, makine öğrenmesi ve derin öğrenme modellerinin performansını değerlendirmek için kullanılan önemli bir araçtır. Özellikle sınıflandırma problemlerinde, modelin tahminlerinin doğruluğunu ve hata türlerini anlamak için

kullanılır. Karışıklık matrisi, gerçek sınıf etiketleri ile modelin tahmin ettiği etiketleri karşılaştırarak oluşturulur. Matrisin yapısı şu şekildedir:

Doğru Pozitif (True Positive - TP): Modelin doğru olarak pozitif olarak tahmin ettiği örneklerin sayısı.

Doğru Negatif (True Negative - TN): Modelin doğru olarak negatif olarak tahmin ettiği örneklerin sayısı.

Yanlış Pozitif (False Positive - FP): Modelin yanlış olarak pozitif olarak tahmin ettiği örneklerin sayısı (Tip I hata).

Yanlış Negatif (False Negative - FN): Modelin yanlış olarak negatif olarak tahmin ettiği örneklerin sayısı (Tip II hata).

Bu dört değer, modelin performansını değerlendirmek için farklı metriklerin hesaplanmasında kullanılır. Örneğin, doğruluk (accuracy), hassasiyet (precision), geri çağırma (recall) ve F1-skoru gibi metrikler, karışıklık matrisindeki değerlerden hesaplanabilir. Karışıklık matrisi, modelin güçlü ve zayıf yönlerini anlamak için de kullanılabilir. Örneğin, yüksek bir yanlış pozitif oranı, modelin çok fazla örneği yanlışlıkla pozitif olarak sınıflandırdığını gösterir. Bu bilgi, modelin iyileştirilmesi için hangi alanlara odaklanılması gerektiğini belirlemeye yardımcı olabilir. Karışıklık matrisi, bir sınıflandırma modelinin gerçek değerlerin bilindiği bir test veri seti üzerindeki performansını ölçmek için kullanılan standart bir yöntemdir (Powers, 2020). Bu matris, modelin genel doğruluğunun yanı sıra farklı hata türlerini de analiz etmeyi sağlar. Çizelge 3.1.'de karışıklık matrisi gösterilmektedir.

Çizelge 3.1. Karışıklık (hata) matrisi

		TAHMİN	
		YOK	VAR
GERÇEK	YOK	TN	FP
	VAR	FN	TP

Özetle, karışıklık matrisi, derin öğrenme ve makine öğrenmesi modellerinin performansını değerlendirmek ve anlamak için kullanılan güçlü bir araçtır. Modelin tahminlerinin doğruluğunu ve hata türlerini analiz ederek, modelin iyileştirilmesi ve daha doğru tahminler yapması için yol gösterir.

$$\text{TOPLAM DEĞER} = \text{TN} + \text{FN} + \text{TP} + \text{FP} \quad (3.7)$$

$$\text{Gerçek Pozitif Değer} = \text{FN} + \text{TP} \quad (3.8)$$

$$\text{Gerçek Negatif Değer} = \text{FP} + \text{TN} \quad (3.9)$$

3.2.3.2. ROC Eğrisi

ROC eğrisi (Receiver Operating Characteristic), ikili sınıflandırma problemlerinde bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir grafiksel araçtır. Bu eğri, farklı eşik değerlerinde doğru pozitif oranı (hassasiyet) ve yanlış pozitif oranı (1 - özgüllük) arasındaki ilişkiyi gösterir. Doğru pozitif oranı, gerçekte pozitif olan örneklerin doğru olarak pozitif olarak sınıflandırılma oranıdır. Yanlış pozitif oranı ise gerçekte negatif olan örneklerin yanlışlıkla pozitif olarak sınıflandırılma oranıdır. ROC eğrisinde x eksenini yanlış pozitif oranı, y eksenini ise doğru pozitif oranını gösterir. Eğri, farklı eşik değerlerinde elde edilen hassasiyet ve özgüllük değerlerini birleştiren noktaların birleşiminden oluşur. ROC eğrisinin altında kalan alan (Area Under Curve - AUC), modelin genel performansını özetleyen bir değerdir. AUC değeri 0.5'ten büyükse, model rastgele tahmin yapmaktan daha iyidir. AUC değeri 1'e yaklaştıkça modelin performansı artar. ROC eğrisinin avantajları arasında eşik değerinden bağımsız olması, sınıf dengesizliklerine dayanıklı olması ve farklı sınıflandırma modellerinin performanslarını karşılaştırmak için kullanılabilmesi sayılabilir. ROC eğrisi, tıp, finans, makine öğrenmesi gibi birçok alanda kullanılır. Özetle, ROC eğrisi, bir sınıflandırma modelinin ne kadar iyi bir iş çıkardığını, yani pozitif örnekleri negatif örneklerden ne kadar iyi ayırt ettiğini görsel olarak gösteren güçlü bir araçtır. ROC eğrisi, görsel bir temsil olsa da, temelini oluşturan matematiksel hesaplamalar vardır. Bu hesaplamalar, doğru pozitif oranı (True Positive Rate - TPR) ve yanlış pozitif oranı (False Positive Rate - FPR) kavramlarına dayanır. TPR, pozitif sınıf örneklerinin ne kadar doğru tahmin edildiğini gösterirken, FPR ise negatif sınıf örneklerinin yanlışlıkla pozitif olarak sınıflandırılma oranını gösterir. Denklem 3.10 ve 3.11'de TPR ve FPR formülleri verilmiştir.

$$\text{TPR} = \text{TP} / (\text{TP} + \text{FN}) \quad (3.10)$$

$$\text{FPR} = \text{FP} / (\text{FP} + \text{TN}) \quad (3.11)$$

3.2.3.3. Doğruluk Oranı

Sınıflandırmaya bağlı problemlerde, bir modelin başarısını ölçmek için kullanılan en yaygın metriklerden biri doğruluktur. Doğruluk (Accuracy), modelin doğru bir şekilde sınıflandırdığı örneklerin oranını temsil eder. Karışıklık matrisi üzerinden hesaplandığında, doğruluk şu şekilde ifade edilebilir:

$$\text{Doğruluk} = (\text{Doğru Pozitif} + \text{Doğru Negatif}) / \text{Toplam Örnek Sayısı}$$

Formül olarak:

$$\text{Doğruluk} = \frac{(\text{TP} + \text{TN})}{(\text{TP} + \text{FP} + \text{FN} + \text{TN})} \quad (3.12)$$

Doğruluk, modelin genel performansını anlamak için basit ve kullanışlı bir metriktir. Ancak, veri setindeki sınıfların dengesiz dağıldığı durumlarda yanıltıcı olabilir. Bu gibi durumlarda, hassasiyet, geri çağırma ve F1-skoru gibi diğer metrikleri de değerlendirmek önemlidir.

3.2.3.4. Duyarlılık / Hassasiyet

Duyarlılık / Hassasiyet (Sensitivity / Recall), bir sınıflandırma modelinin gerçekte pozitif olan örnekleri ne kadar iyi tespit ettiğini ölçen bir metriktir. Başka bir deyişle, modelin gerçek pozitif oranını (True Positive Rate - TPR) temsil eder. TPR, modelin pozitif olarak doğru bir şekilde sınıflandırdığı örneklerin, gerçekte pozitif olan tüm örneklerin sayısına oranıdır. Duyarlılık, isabet oranı veya hatırlama oranı (recall) olarak da adlandırılır. Yüksek bir duyarlılık değeri, modelin gerçek pozitifleri tespit etmede başarılı olduğunu gösterir. Duyarlılık, özellikle yanlış negatiflerin (FN) önemli olduğu durumlarda kritik bir metriktir. Yanlış negatif, gerçekte pozitif olan bir örneğin model tarafından negatif olarak sınıflandırılmasıdır. Örneğin, kanser teşhisi gibi bir uygulamada, yanlış negatif sonuçlar ciddi sonuçlara yol açabilir. Duyarlılık şu şekilde hesaplanır:

$$\text{Duyarlılık (TPR)} = \text{TP} / (\text{TP} + \text{FN}) \quad (3.13)$$

Duyarlılık değeri 0 ile 1 arasında değişir ve 1'e yaklaştıkça modelin gerçek pozitifleri tespit etmedeki başarısı artar. Özetle, duyarlılık, bir sınıflandırma modelinin gerçek pozitifleri ne kadar iyi tespit ettiğini ölçen ve özellikle yanlış negatiflerin önemli olduğu durumlarda dikkate alınması gereken bir metriktir.

3.2.3.5. Kesinlik

Kesinlik (Precision), bir sınıflandırma modelinin pozitif olarak tahmin ettiği örnekler arasında gerçekte kaçının pozitif olduğunu ölçen bir metriktir. Yani, modelin pozitif tahminlerinin doğruluk oranını temsil eder. Kesinlik, pozitif tahmin edici değer (Positive Predictive Value - PPV) olarak da adlandırılır. Yüksek bir kesinlik değeri, modelin pozitif olarak tahmin ettiği örneklerin çoğunun gerçekten pozitif olduğunu gösterir. Kesinlik, özellikle yanlış pozitiflerin (FP) önemli olduğu durumlarda kritik bir metriktir. Yanlış pozitif, gerçekte negatif olan bir örneğin model tarafından pozitif olarak sınıflandırılmasıdır. Örneğin, spam filtreleme gibi bir uygulamada, yanlış pozitif sonuçlar önemli e-postaların spam olarak işaretlenmesine neden olabilir. Kesinlik şu şekilde hesaplanır:

$$\text{Kesinlik} = \text{TP} / (\text{TP} + \text{FP}) \quad (3.14)$$

Kesinlik değeri 0 ile 1 arasında değişir ve 1'e yaklaştıkça modelin pozitif tahminlerindeki doğruluk oranı artar. Özetle, kesinlik, bir sınıflandırma modelinin pozitif tahminlerinin ne kadar doğru olduğunu ölçen ve özellikle yanlış pozitiflerin önemli olduğu durumlarda dikkate alınması gereken bir metriktir.

F-1 Puanı

F-1 puanı / F-1 skoru (F-1 Score), bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir metriktir. Hassasiyet ve duyarlılığın harmonik ortalaması olarak hesaplanır. Hassasiyet, modelin pozitif tahmin ettiği örnekler arasında gerçekte kaçının pozitif olduğunu ölçerken, duyarlılık ise modelin gerçekte pozitif olan örnekleri ne kadar iyi tespit ettiğini ölçer. F-1puanı, bu iki metriği tek bir değerde birleştirerek modelin genel performansını daha dengeli bir şekilde yansıtır. Özellikle dengesiz veri setlerinde, doğruluk metriği yanıltıcı olabilirken, F-puanı daha doğru bir değerlendirme sağlar. F-1 puanı, genellikle F1-skoru olarak adlandırılır ve şu şekilde hesaplanır:

$$F1\text{-puanı} = 2 * (\text{Hassasiyet} * \text{Duyarlılık}) / (\text{Hassasiyet} + \text{Duyarlılık}) \quad (3.15)$$

F1-skoru 0 ile 1 arasında bir deęer alır ve 1'e yaklaştıkça modelin performansı artar. F1-skoru, sınıflandırma problemlerinde yaygın olarak kullanılan bir metriktir ve özellikle modelin hem hassasiyet hem de duyarlılık açısından iyi performans göstermesi istendiğinde tercih edilir.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bitkilerin sağlık durumları, sadece yapraklarındaki belirtilerle değil, aynı zamanda genel görünümüleriyle de ortaya çıkar. Bir bitkinin hastalık durumunu sadece görsel inceleme ile anlamak, özellikle uzman olmayan kişiler için zorlu ve zaman alıcı olabilir. Günümüzde, teknolojinin hızla gelişmesi ve tarım alanında artan veri karmaşıklığı, yapay zekâ (AI), görüntü işleme ve bitki hastalığı tespiti üzerinde yoğun çalışmalara yol açmıştır. Bitki hastalıklarını tanımak için yapılan araştırmalarda, görüntü analizi önemli bir rol oynar. Otomatik hastalık tespiti, tarımda verimliliği artırmak, ürün kayıplarını azaltmak ve kimyasal ilaç kullanımını en aza indirmek için kritik öneme sahiptir. Bu alanda, özellikle görüntü tabanlı hastalık tanıma yöntemleri, bitki yapraklarındaki veya genel görüntülerindeki desenleri analiz ederek hastalıkları tespit etmekle sorumludur. Hastalık tespiti, renk değişiklikleri, lekeler, desenler ve yaprak deformasyonları gibi faktörlere dayanarak gerçekleştirilir.

Bu çalışmada, patates bitkilerindeki hastalıkların görüntü analizi ile tespiti için derin öğrenme yöntemlerinden yararlanılmıştır. Özellikle, ResNet (Residual Network) mimarisi ve transfer öğrenme yaklaşımı birleştirilerek, daha önce büyük veri kümeleri üzerinde eğitilmiş olan bir modelin, patates hastalıklarının tespiti için uyarlanması hedeflenmiştir. Transfer öğrenme sayesinde, model, genel görüntü tanıma konusunda kazandığı bilgileri, daha spesifik bir görev olan patates hastalığı tespitine aktararak, daha az veri ile daha iyi sonuçlar elde etmiştir. ResNet mimarisi ise, derin ağlarda sıkça karşılaşılan gradyan kaybolması sorununu çözerek, modelin daha derin katmanlarda da etkili bir şekilde öğrenmesini sağlamıştır. Bu sayede, model, patates bitkilerindeki hastalıkları daha doğru ve güvenilir bir şekilde teşhis edebilme yeteneği kazanmıştır. ResNet modellerinin avantajları arasında şunlar bulunur:

Eğitim kolaylığı: Artık bağlantılar sayesinde derin ağlar daha kolay eğitilebilir.

Daha derin ağlar: ResNet mimarisi, çok derin ağların başarılı bir şekilde eğitilmesini mümkün kılar.

Aşırı uyum sorunlarının azaltılması: Artık bağlantılar, aşırı uyum problemini azaltmaya yardımcı olur.

ResNet mimarisi, derin öğrenme modellerinin başarısını önemli ölçüde artırmıştır. Özellikle ImageNet gibi büyük ölçekli görüntü tanıma görevlerindeki üstün performansı ile dikkat çekmiştir. ResNet'in temel özelliği olan artımlı bağlantılar, modelin daha derin katmanlarda da etkili bir şekilde öğrenmesini sağlayarak, daha karmaşık görsel özellikleri

yakalamasını mümkün kılmıştır. Bu çalışmada ResNet-18, ResNet-50, ResNet-152, ResNeXt ve bu modelleri kullanılmıştır. Modelin mimarisi şu şekildedir:

Model çıktısı bir global havuzlama katmanına verilir. Global havuzlama, özellik haritalarından en önemli bilgileri çıkararak modelin hesaplama maliyetini azaltır. Global havuzlama katmanından sonra, aşırı uyum problemlerini engellemek için bir Dropout katmanı kullanılır. Dropout, rastgele nöronları devre dışı bırakarak modelin genelleme yeteneğini artırır. Daha sonra, 128 nörondan oluşan bir yoğun (Dense) katman kullanılır. Bu katman, özellikleri daha yüksek seviyede birleştirir. Son katmanda, girilen bir patates görüntüsünün ilgili sınıfa (hastalık türü veya sağlıklı) ait olma olasılığını hesaplayan, 7 çıkışlı bir Dense katmanı bulunduran softmax aktivasyon fonksiyonudur. Bu mimari, patates görüntülerinden hastalık tespiti görevini etkili bir şekilde gerçekleştirmek için tasarlanmıştır.

Çizelge 4.1. Genel ResNet model mimarileri

```
x=base_model.output(ResNet18, ResNet50, Resnet152, ResNeXt)
x =Global Average Pooling 2D()(x)
x =Dropout (0.3) (x)
x =Dense (128, activation='relu')(x)
tahminler = Dense(7, activation='softmax')(x)
```

Bu çalışmada kullanılan, aynı hiperparametre değerleri ile eğitilmiş olan ResNet modelleri Çizelge 4.1'de gösterilmiştir. Bu değerler, çeşitli denemeler sonucunda elde edilen en iyi performansı sağlayan değerlerdir.

Optimizasyon Algoritması: Denemeler sonucunda en iyi optimizasyon algoritması olarak "Adam" seçilmiştir. Adam, derin öğrenme modellerinde yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Momentum ve RMSprop gibi teknikleri birleştirerek, daha hızlı ve stabil bir öğrenme süreci sağlar.

Batch Size: Batch size, 64 olarak belirlenmiştir. Batch size, her iterasyonda modele verilen örnek sayısını ifade eder. 64 değeri, bu çalışmada kullanılan veri seti ve donanım için iyi bir denge sağlamıştır.

Kayıp Fonksiyonu: Kayıp fonksiyonu olarak "Sparse Categorical Crossentropy" kullanılmıştır. Bu fonksiyon, çok sınıflı sınıflandırma problemleri için uygun bir kayıp fonksiyonudur ve modelin tahminlerinin gerçek etiketlerden ne kadar farklı olduğunu ölçer.

Öğrenme Oranı: Öğrenme oranı, 0.001 olarak ayarlanmıştır. Öğrenme oranı, modelin ağırlıklarının her iterasyonda ne kadar güncelleneceğini belirler. 0.001 değeri, bu çalışmada iyi bir öğrenme performansı sağlamıştır.

Bu metrikler, modelin farklı yönlerini değerlendirerek genel performansını anlamamıza yardımcı olur. Çizelge 4.2’de gösterilen parametreler bu modellere aittir.

Çizelge 4.2. ResNet modeller hiperparametre değerleri

Hiperparametreler	Değer
batch_size	64
epoch	100
Metriks	accuracy', 'loss', 'precision', 'recall', 'AUC', 'f1_score'
optimizer	Adam
learning_rate	0,001
losses function	SparceCategoricalCrossentropy

ResNet modelleri bu çalışmada %80-20 eğitim-test oranları verilerek çalıştırılmıştır. Bu çalışmada, patates hastalıklarının tespiti için dört farklı ResNet modeli (ResNet18, ResNet50, ResNet152 ve ResNeXt) kullanılmış ve performansları karşılaştırılmıştır. Veri seti 224x224 pikselleri renkli görüntülerden oluşmaktadır. Bu görüntüler patates yapraklarının erken yanıklık, geç yanıklık ve sağlıklı olmak üzere 3 sınıflandırma modellemesi yapılmıştır. Çizelge 4.3 ve Çizelge 4.4’te veri seti için toplanan performans değerleri verilmiş, elde edilen sonuçlar tabloda özetlenmiştir.

Çizelge 4.3. Resnet Modellerinin Doğruluk oranları

Model Adı	Resnet18	Resnet50	Resnet152	ResNeXt
Doğruluk Oranı	0.96	0.97	0.98	0.98

Çizelge 4.3’te görüldüğü üzere; bu çalışmada, patates hastalıklarının tespiti için dört farklı ResNet modeli (ResNet18, ResNet50, ResNet152 ve ResNeXt) kullanılmış ve performansları karşılaştırılmıştır. Tablo incelendiğinde, tüm modellerin genel olarak yüksek performans gösterdiği görülmektedir. ResNet152 ve ResNeXt modelleri, %98’lik doğruluk oranıyla en yüksek başarıyı elde etmiştir.

Çizelge 4.4. Eğitilen Resnet Modelleri ve Eğitim-Test veri setinin performans çıktıları

Model Adı	Patates Erken Yanıklık		
	Hassasiyet	Kesinlik	F-1 Skoru
Resnet18	0.96	0.99	0.98
Resnet50	0.97	0.99	0.98
Resnet152	0.99	0.99	0.99
ResNeXt	0.99	0.99	0.99
Model Adı	Patates Geç Yanıklık		
	Hassasiyet	Kesinlik	F-1 Skoru
Resnet18	0.99	0.92	0.95
Resnet50	0.97	0.97	0.97
Resnet152	0.98	0.97	0.97
ResNeXt	0.99	0.97	0.98
Model Adı	Patates Sağlıklı		
	Hassasiyet	Kesinlik	F-1 Skoru
Resnet18	0.84	0.97	0.90
Resnet50	0.97	0.89	0.93
Resnet152	0.88	0.97	0.92
ResNeXt	0.85	0.92	0.88
Model Adı	Model Metrik Ortalamaları		
	Hassasiyet	Kesinlik	F-1 Skoru
Resnet18	0.93	0.96	0.94
Resnet50	0.97	0.95	0.96
Resnet152	0.95	0.97	0.96
ResNeXt	0.94	0.96	0.95
Model Adı	Model Ağırlıklı Ortalamaları		
	Hassasiyet	Kesinlik	F-1 Skoru
Resnet18	0.96	0.96	0.96
Resnet50	0.97	0.97	0.97
Resnet152	0.98	0.98	0.98
ResNeXt	0.98	0.98	0.98


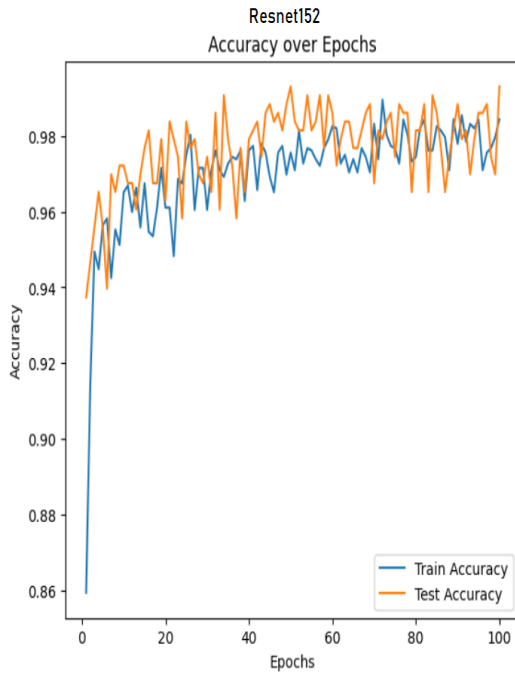

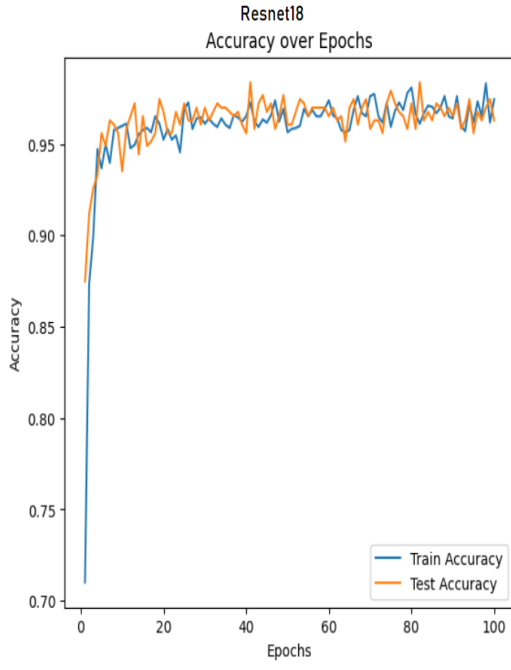
Diğer modellere kıyasla Çizelge 4.4'te görüldüğü üzere, bu iki modelin özellikle "Geç Yanıklık" ve "Sağlıklı" sınıflarında daha yüksek hassasiyet ve F1-skoru değerlerine sahip olduğu dikkat çekmektedir. Bu durum, ResNet152 ve ResNeXt'in daha derin mimarileri sayesinde karmaşık özellikleri daha iyi öğrenebildiklerini ve patates hastalıklarını daha doğru bir şekilde sınıflandırabildiklerini göstermektedir. ResNet18 ve ResNet50 modelleri ise sırasıyla %96 ve %97 doğruluk oranlarına ulaşmıştır. Bu modeller, ResNet152 ve ResNeXt'e göre daha az katmana sahip oldukları için daha hızlı eğitilebilirler. Ancak, daha az derin olmaları nedeniyle bazı durumlarda performansları daha düşük olabilir. Metrikler açısından değerlendirildiğinde:

Kesinlik: Tüm modeller, "Erken Yanıklık" sınıfında çok yüksek kesinlik değerleri (%96 ve üzeri) elde etmiştir. Bu, modellerin erken yanıklığı tespit etmede oldukça başarılı olduğunu gösterir.

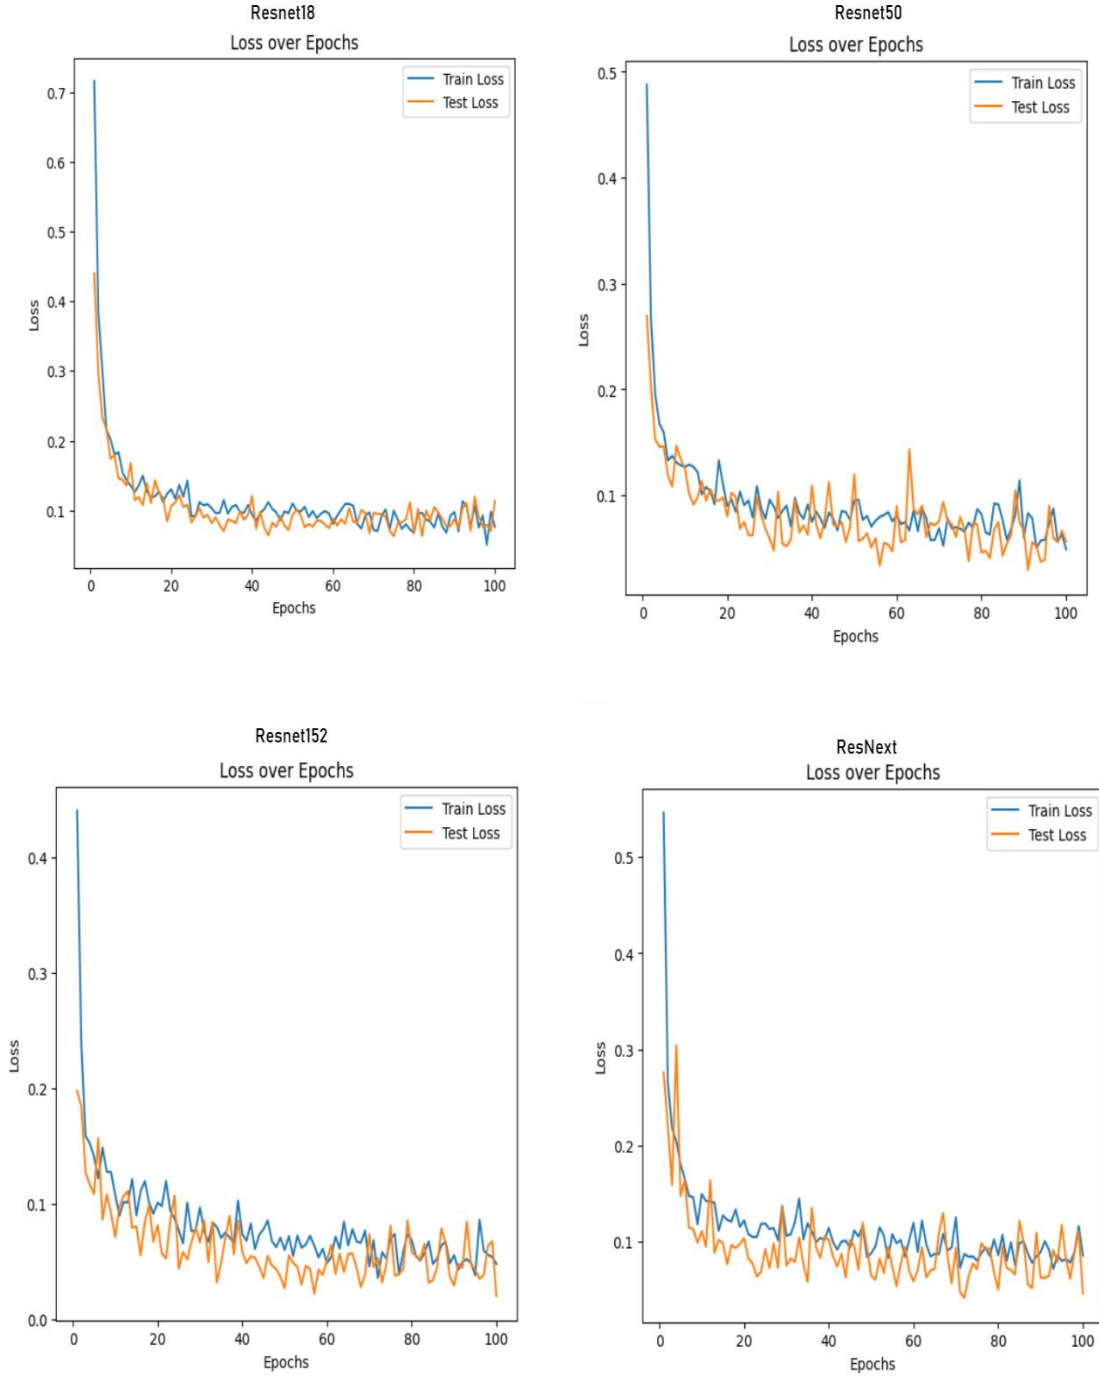
Duyarlılık: ResNet18 ve ResNet50, "Erken Yanıklık" sınıfında %99'luk duyarlılık oranıyla mükemmel bir performans sergilemiştir. Diğer sınıflar için duyarlılık değerleri de genel olarak yüksektir.

F1-skoru: F1-skoru, hassasiyet ve duyarlılığın harmonik ortalamasıdır ve modelin genel performansını dengeli bir şekilde yansıtır. Tüm modeller, farklı sınıflar için yüksek F1-skoru değerlerine ulaşmıştır.

Sonuç olarak, bu çalışma patates hastalıklarının tespiti için derin öğrenme modellerinin etkili bir şekilde kullanılabileceğini göstermektedir. ResNet152 ve ResNeXt modelleri, en yüksek doğruluk oranlarını elde etmiş ve diğer metrikler açısından da başarılı bir performans sergilemiştir. Çizelgeye bakıldığında Resnet18 modelinin diğer modelleri gerisinde kaldığı görülmektedir. Bu modeller, patates yetiştiriciliğinde hastalık tespiti ve mücadelesi için değerli araçlar olabilir. Modelin eğitim süreci boyunca elde ettiği sonuçlar, Şekil 4.1'deki başarı grafikleri ve Şekil 4.2'deki kayıp-hata grafikleri ile detaylı bir şekilde incelenmiştir. Bu grafikler, modelin her bir iterasyonda ne kadar iyi öğrendiğini ve ne kadar hata yaptığını göstermektedir.



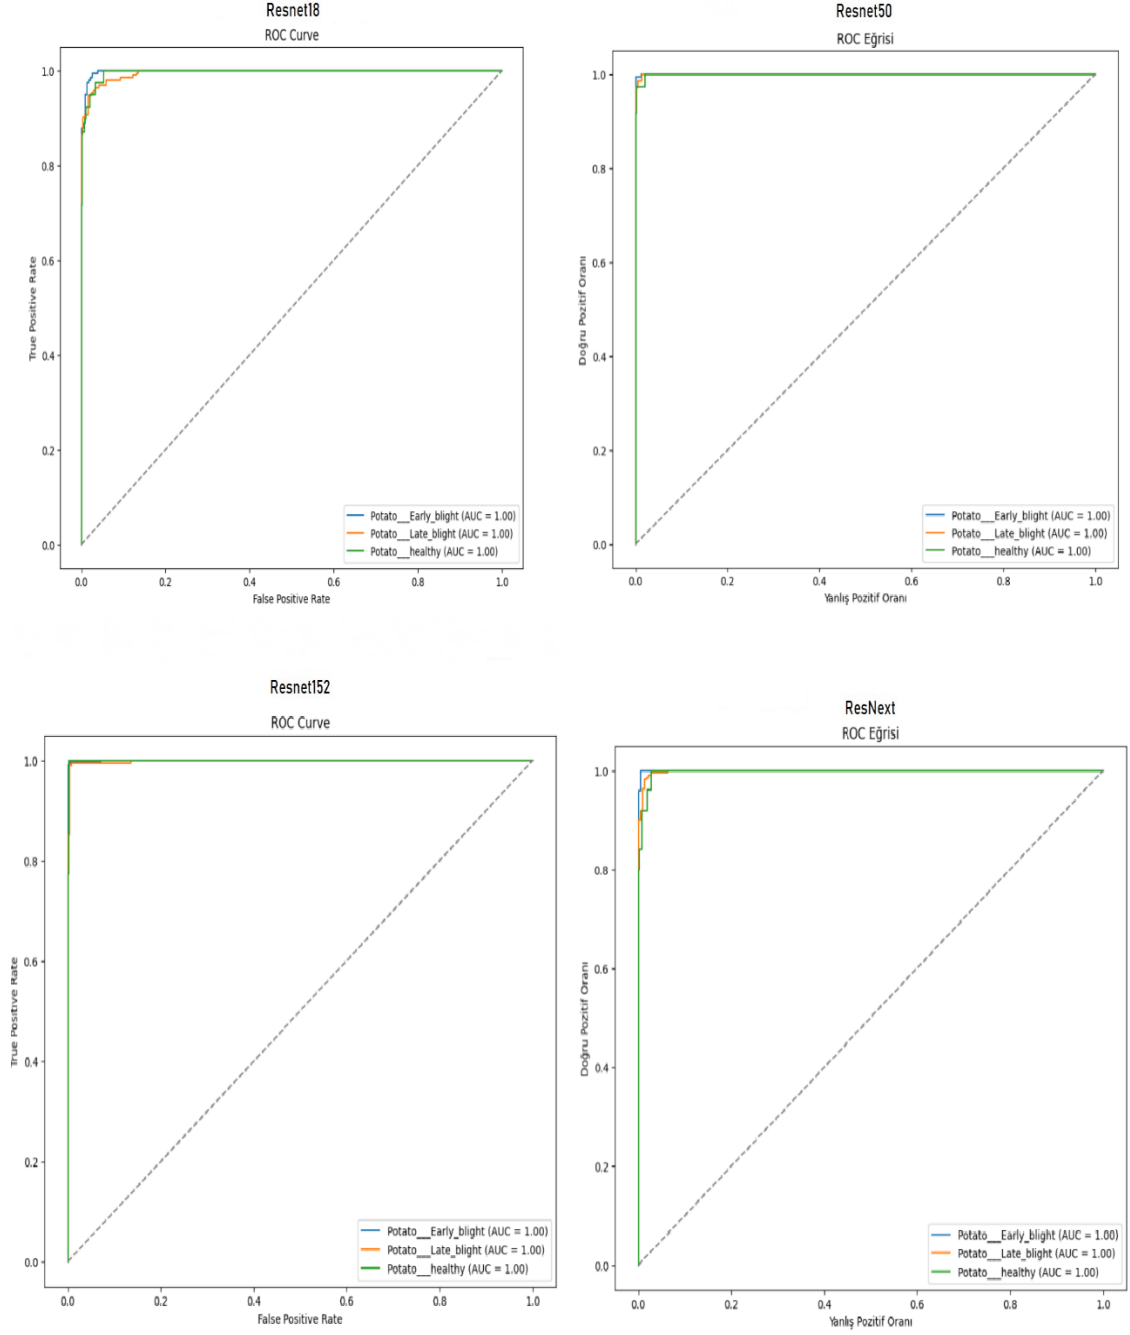
Şekil 4.1. ResNet modellerine ait başarı oranları



Şekil 4.2. ResNet modellerine ait kayıp değer grafikleri

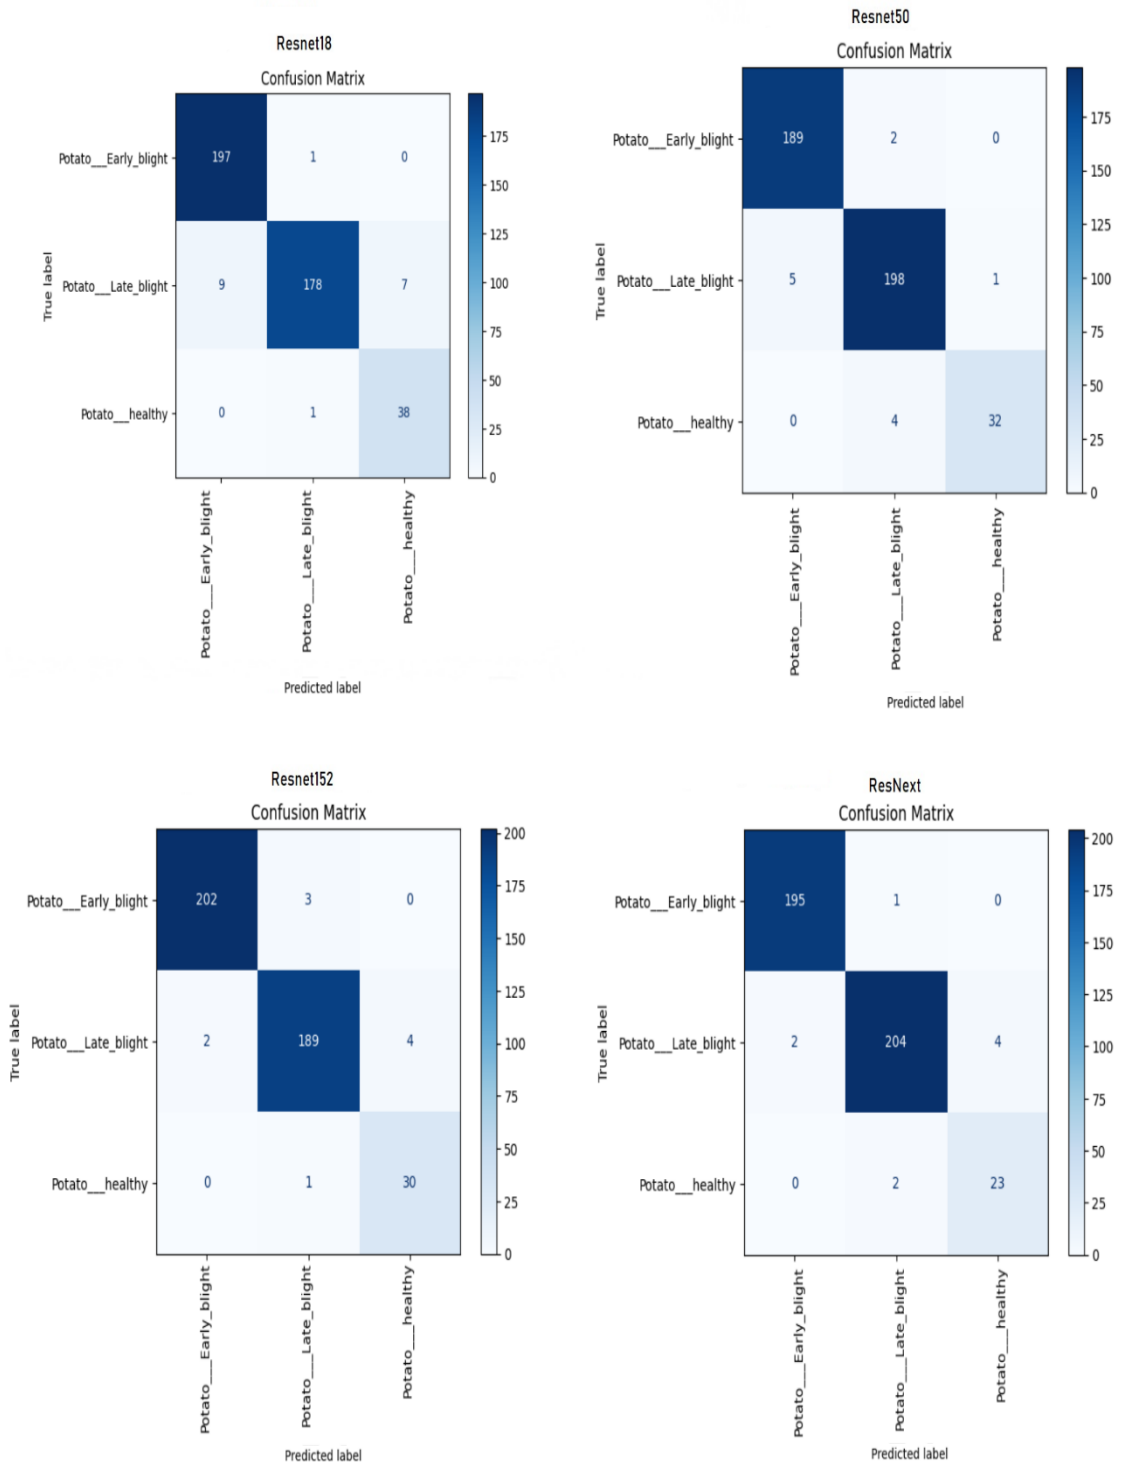
ROC eğrisi, bir sınıflandırma modelinin farklı eşik değerlerindeki performansını görselleştirerek, modelin hassasiyet ve özgüllük arasındaki dengeyi değerlendirmek için kullanılan bir araçtır. Hassasiyet, modelin pozitif örnekleri doğru bir şekilde sınıflandırma oranını, özgüllük ise negatif örnekleri doğru bir şekilde sınıflandırma oranını ifade eder. ROC eğrisi, sol üst köşeye doğru yükseldikçe modelin hem hassasiyeti hem de özgüllüğü artar. AUC değeri ise, ROC eğrisi altındaki alanı ifade eder ve modelin genel sınıflandırma performansını ölçmek için kullanılan önemli bir metriktir. AUC değeri 1'e

ne kadar yakınsa, model o kadar iyi bir ayırım yeteneğine sahiptir. Ayrıca, farklı modellerin performansını karşılaştırmak ve en uygun sınıflandırma eşiğini belirlemek için de kullanılabilir. ROC analizi, tıp, finans ve güvenlik gibi alanlarda yaygın olarak kullanılır. Örneğin, bir hastalık teşhis modelinin performansını değerlendirmek veya kredi kartı sahtekarlığını tespit etmek için kullanılabilir. Özetle, ROC eğrisi ve AUC, bir sınıflandırma modelinin performansını ayrıntılı bir şekilde değerlendirmek ve farklı sınıflandırma eşiklerindeki davranışını anlamak için kullanılan önemli araçlardır. Modellere ait ROC grafikleri Şekil 4.3'te verilmiştir. Bu grafiklere göre ROC eğrilerinin sol üst köşeye yakın olması ve AUC değerlerinin 1.00 olması, modellerin neredeyse mükemmel bir şekilde hastalıkları ayırt edebildiğini gösteriyor. Bu, modellerin hem yüksek hassasiyete (gerçek pozitif oranı) hem de yüksek özgüllüğe (gerçek negatif oranı) sahip olduğunu gösterir. Yani, hem hastalıklı patatesleri doğru bir şekilde tespit edebiliyorlar hem de sağlıklı patatesleri hastalıklı olarak yanlış sınıflandırmıyorlar. ResNet18, ResNet50 ve ResNet152 modellerinde ROC eğrileri neredeyse tamamen üst üste çıkıyor ve AUC değerleri 1.00. olduğundan modellerin performans açısından birbirine çok yakın olduğunu gösteriyor. ResNeXt modelinin ROC eğrisi de sol üst köşeye çok yakın ve AUC değeri 1.00. Ancak, diğer üç modele kıyasla eğri biraz daha "düz" görünüyor. Bu, ResNeXt'in bazı durumlarda diğer modellerden biraz daha fazla yanlış pozitif tahmin yapabileceğini gösterebilir.



Şekil 4.3. ResNet Modellere ait ROC eğrileri

Karışıklık matrisi, modelin güçlü ve zayıf yönlerini anlamak için de kullanılabilir. Örneğin, yüksek bir yanlış pozitif oranı, modelin çok fazla örneği yanlışlıkla pozitif olarak sınıflandırdığını gösterir. Bu bilgi, modelin iyileştirilmesi için hangi alanlara odaklanılması gerektiğini belirlemeye yardımcı olabilir. Şekil 4.4'te bu modellere ait Karışıklık Matrisi Grafikleri verilmiştir.



Şekil 4.4. Karışıklık Matrisleri Grafiği

Verilen grafikler, dört farklı ResNet modelinin (ResNet18, ResNet50, ResNet152 ve ResNeXt) patates hastalıklarını sınıflandırma performansını gösteren karışıklık matrisleridir. Bu grafiklere baktığımızda ResNet18 "Erken Yanıklık" sınıfında yüksek performans gösterirken, "Geç Yanıklık" ve "Sağlıklı" sınıflarında bazı hatalar yapmaktadır. ResNet50 ise ResNet18'e benzer bir performans sergiler, ancak "Sağlıklı"

sınıfında daha az hata yaptığı gözlenlenmiştir. ResNet152, tüm sınıflar için yüksek doğruluk oranları elde ederken özellikle "Geç Yanıklık" sınıfında çok başarılı olduğu görülmektedir. ResNeXt, ResNet152'ye benzer bir performans gösterir, ancak "Erken Yanıklık" sınıfında biraz daha fazla hata yaptığı görülmektedir. Genel olarak, tüm modellerin "Erken Yanıklık" sınıfını tespit etmede başarılı olduğu, ancak "Geç Yanıklık" ve "Sağlıklı" sınıflarını ayırt etmede bazı zorluklar yaşadığı görülmektedir. ResNet152 ve ResNeXt, daha derin mimarileri sayesinde diğer modellere göre daha yüksek performans göstermektedir.

5. SONUÇLAR VE ÖNERİLER

Yapay zeka ve görüntü işleme teknolojilerindeki hızlı gelişmeler, tarım sektöründe hastalık tespiti için yeni ufuklar açmıştır. Bitki hastalıklarının erken tespiti, tarımsal verimlilik ve ürün kalitesini doğrudan etkileyen önemli bir faktördür. Görüntü işleme algoritmaları sayesinde, bitki yapraklarındaki lezyonlar, renk değişimleri gibi görsel belirtiler otomatik olarak tespit edilebilmekte ve sınıflandırılabilir. Bu sayede, insan hatası riskini minimize eden ve daha hızlı teşhis imkanı sunan bir sistem geliştirilmektedir. Derin öğrenme gibi yapay zeka tekniklerinin kullanımıyla, büyük veri kümeleri üzerinde eğitilen modeller, karmaşık hastalık desenlerini tanıma yeteneği kazanmaktadır. Bu durum, tarım sektöründe daha doğru ve etkili hastalık yönetimi stratejilerinin geliştirilmesine katkı sağlamaktadır. Bu çalışma, patates bitkisindeki hastalıkların görüntü işleme ve derin öğrenme yöntemleri ile otomatik olarak tespit edilmesine odaklanmaktadır. Patates, dünya genelinde en önemli besin kaynaklarından biridir ve bu bitkide meydana gelen hastalıklar, verim ve kalite açısından ciddi kayıplara yol açabilmektedir. Bu nedenle, hastalıkların erken ve doğru bir şekilde tespit edilmesi büyük önem taşımaktadır. Derin öğrenme modelleri, özellikle evrimsel sinir ağları (CNN), görüntü tanıma ve sınıflandırma görevlerinde oldukça başarılı sonuçlar vermektedir. Bu çalışmada, derin öğrenme mimarilerinden biri olan Residual Network (ResNet) kullanılmıştır. ResNet, derin sinir ağlarının eğitimini kolaylaştırmak ve derinlik arttıkça oluşan gradyan kaybolması (vanishing gradient) sorunlarını azaltmak amacıyla geliştirilmiş bir mimaridir (He, vd. 2016). Derin ağ yapısı sayesinde, ResNet karmaşık özellikleri ve desenleri öğrenme konusunda oldukça etkilidir.

Bu tez çalışmasında, patates bitkilerinde yaygın olarak görülen hastalıkların tespiti için ResNet tabanlı bir derin öğrenme modeli değerlendirilmiştir. Modelin performansını en üst düzeye çıkarmak için, eğitim ve test aşamalarında kullanılan hiperparametreler titizlikle seçilmiştir. Bu çalışmada, optimizasyon algoritması olarak Adam, öğrenme oranı olarak 0.001 ve kayıp fonksiyonu olarak ise Sparse Categorical Crossentropy kullanılmıştır. Bu hiperparametrelerin kombinasyonu, modelin verileri daha iyi öğrenmesini ve genelleme yeteneğini artırmasını sağlamıştır (Çizelge 4.2). Çalışmada kullanılan veri seti Keegle'dan PillantVillage veri setinden alınmıştır. Bu model, sağlıklı ve hastalıklı patates yapraklarının görüntülerini içeren geniş bir veri kümesi üzerinde eğitilmiştir. Modelin eğitim seti üzerindeki performansını ölçmek amacıyla, başarı, kesinlik, karmaşıklık matrisi ve ROC eğrisi gibi çeşitli metrikler

hesaplanmıştır. Bu metrikler, modelin sınıflandırma başarısını farklı açılardan değerlendirmemizi sağlamıştır. Eğitim ve test aşamalarında kullanılan ResNet modeli, farklı katman sayılarına (ResNet18, ResNet50, ResNet152, ResNeXt) sahip versiyonları ile değerlendirilmiş ve Modelin eğitim seti üzerindeki performansı, başarı oranı, kesinlik, duyarlılık, F1 skoru ve ROC eğrisi gibi çoklu performans metrikleri kullanılarak kapsamlı bir şekilde değerlendirilmiştir (Çizelge 4.3). Bu metrikler sayesinde, modelin farklı açılardan incelenmesi ve genel performansının daha iyi anlaşılması mümkün olmuştur. Bu sonuçlara göre, patates hastalıklarının tespiti için dört farklı ResNet modeli (ResNet18, ResNet50, ResNet152 ve ResNeXt) kullanılmış ve performansları çeşitli metrikler ve görselleştirme araçları kullanılarak değerlendirilmiştir. Genel olarak, tüm modellerin yüksek performans gösterdiği gözlemlenmiştir. Ancak ResNet152 ve ResNeXt modelleri, %98'lik doğruluk oranıyla en yüksek başarıyı elde etmiştir. Bu iki model, özellikle "Geç Yanıklık" ve "Sağlıklı" sınıflarında daha yüksek hassasiyet ve F1-skoru değerlerine ulaşmıştır. Bu durum, ResNet152 ve ResNeXt'in daha derin mimarileri sayesinde karmaşık özellikleri daha iyi öğrenebildiklerini ve patates hastalıklarını daha doğru bir şekilde sınıflandırabildiklerini göstermektedir. ResNet18 ve ResNet50 modelleri ise sırasıyla %96 ve %97 doğruluk oranlarına ulaşmıştır. Bu modeller, ResNet152 ve ResNeXt'e göre daha az katmana sahip oldukları için daha hızlı eğitilebilirler. Ancak, daha az derin olmaları nedeniyle bazı durumlarda performansları daha düşük olabilmektedir. Modellemelere metrikler (kesinlik, duyarlılık, F1-skoru) açısından incelediğimizde baktığımızda ise; tüm modeller, "Erken Yanıklık" sınıfında çok yüksek kesinlik değerleri (%96 ve üzeri) elde etmiştir. Bu, modellerin erken yanıklığı tespit etmede oldukça başarılı olduğunu gösterir. ResNet18 ve ResNet50, "Erken Yanıklık" sınıfında %99'luk duyarlılık oranıyla mükemmel bir performans sergilemiştir. Diğer sınıflar için duyarlılık değerleri de genel olarak yüksektir. Ayrıca tüm modeller, farklı sınıflar için yüksek F1-skoru değerlerine ulaşmıştır ancak en yüksek F1 değeri Resnet152'ye ait olduğu görülmektedir. Bu, modellerin hem hassasiyet hem de duyarlılık açısından dengeli bir performans gösterdiğini gösterir. ROC eğrileri ve karışıklık matrisleri incelendiğinde ise; ROC eğrilerinin sol üst köşeye yakın olması ve AUC değerlerinin 1.00 olması, modellerin neredeyse mükemmel bir şekilde hastalıkları ayırt edebildiğini göstermektedir. Karışıklık matrisleri, tüm modellerin "Erken Yanıklık" sınıfını tespit etmede başarılı olduğunu, ancak "Geç Yanıklık" ve "Sağlıklı" sınıflarını ayırt etmede bazı zorluklar yaşayabileceğini göstermektedir. ResNet152 ve ResNeXt,

daha derin mimarileri sayesinde diğer modellere göre daha yüksek performans göstermektedir.

Sonuç olarak, bu çalışma, derin öğrenme modellerinin patates hastalıklarının tespitinde etkili bir şekilde kullanılabilmesini ve özellikle ResNet152 ve ResNeXt gibi derin modellerin yüksek doğruluk oranları sağlayabileceğini göstermiştir. Eğitim seti için en yüksek başarı oranı ResNet152 ve ResNeXt modellerine ait olduğu görülmektedir. Her iki modelin başarı oranı %98'lik doğruluk oranıyla en yüksek başarıyı elde etmiştir. ResNet18 modeli, diğer modellere kıyasla daha düşük performans gösterse de, daha hızlı eğitilebilir olması ve daha az hesaplama kaynağı gerektirmesi nedeniyle bazı uygulamalar için tercih edilebilir. Bu modeller, derin öğrenme yöntemlerinin patates hastalıklarının tespiti konusunda yüksek doğruluk oranlarına ulaşabildiğini göstermektedir. Özellikle, ResNet mimarisinin derin yapısının, karmaşık desenleri ve özellikleri öğrenmede etkili bir strateji olduğunu ortaya koymuştur. Bu sonuçlar, derin öğrenme yöntemlerinin patates hastalıklarının tespiti konusunda yüksek bir potansiyele sahip olduğunu ve tarımsal üretimde verimliliği ve kaliteyi artırmak için değerli araçlar olabileceğini göstermektedir. Derin öğrenmenin tarımsal uygulamadaki ilerlemeleri, erken hastalık tespiti ve müdahale ile ürün kayıplarını minimize ederek sürdürülebilir tarım uygulamalarına katkıda bulunabilir. Ancak, bu teknolojilerin tarım sektöründe yaygın olarak kullanılabilmesi için veri toplama, model eğitimi ve gerçek dünya koşullarında uygulama konularında daha fazla araştırmaya ihtiyaç vardır.

5.1 Hedefler

Bu çalışmanın ana hedefi, yapay zeka ve derin öğrenme yöntemlerinden yararlanarak, patates bitkilerindeki hastalıkların görsel veriler üzerinden otomatik olarak teşhis edilmesi ve sınıflandırılmasıdır. Bu amaç doğrultusunda, ResNet mimarisine dayalı dört farklı model (ResNet18, ResNet50, ResNet152 ve ResNeXt) kullanılmış ve modellerin performansları çeşitli metriklerle değerlendirilmiştir. ResNet mimarisi, derin öğrenme modellerinin karşılaştığı aşırı uyum sorununu çözmek ve daha derin ağların eğitimini kolaylaştırmak amacıyla tasarlanmış bir sinir ağı mimarisidir. Bu sayede, modeller daha karmaşık veri yapılarını daha etkili bir şekilde öğrenebilmektedir. Bu mimari, ağın derinleşmesini sağlayarak daha karmaşık özellikleri öğrenmesine olanak tanır ve bu sayede yüksek doğruluk oranları elde edilebilir.

Çalışmada kullanılan veri seti, PlantVillage veri setinden elde edilmiş ve Kaggle veri tabanından indirilmiştir. Model performansları, başarı oranı, kesinlik, duyarlılık, F1 skoru, ROC eğrisi ve karmaşıklık matrisi gibi çoklu metrikler kullanılarak kapsamlı bir şekilde değerlendirilmiştir. Sonuçlara bakıldığında, ResNet152 ve ResNeXt modellerinin diğer modellerle kıyaslandığında daha yüksek başarı oranlarına sahip olduğunu göstermektedir. Bu modellerin, patates hastalıklarının tespiti ve sınıflandırılması konusunda yüksek performans gösterdiği gözlemlenmiştir. Bu çalışma, patates hastalıklarının görsel veriler üzerinden teşhisi konusunda derin öğrenme modellerinin kullanımının gelecekteki olasılıklarını ve tarım sektörüne sağlayabileceği katkıları ortaya koymaktadır. Ayrıca, yapay zeka destekli bitki hastalığı tanı sistemlerinin geliştirilmesi için araştırmacılara yol gösterici bir kaynak niteliği taşımaktadır.

5.2. Kısıtlamalar

Çalışmanın eksik yönlerine ve sınırlılıklarına bakacak olursak; bu çalışmada derin öğrenme yöntemleri kullanılarak patates görüntülerinden hastalık tespiti konusundaki yüksek değerli sonuçlara rağmen, bazı sınırlamalar mevcuttur. İlk olarak, eğitim ve test aşamalarında kullanılan veri seti, yalnızca PlantVillage isimli veri setinden elde edilmiştir. Bu veri seti, laboratuvar koşullarında toplanmış olabilir ve gerçek tarım alanlarındaki değişken koşulları tam olarak yansıtmayabilir.

İkinci olarak, incelenen modellerin performansı yalnızca belirli metriklerle (başarı, kesinlik, duyarlılık, ROC eğrisi, F1-Ölçütü, Karmaşıklık matrisi) değerlendirilmiştir. Bu ölçütler geniş kapsamlı sonuçlar sunsa da, tarım alanında karşılaşılan çeşitli pratik gereksinimleri tam olarak karşılayamayabilir.

Üçüncü olarak, çalışmanın sonuçları ResNet152 ve ResNeXt modellerinin diğer modellere kıyasla daha yüksek başarı oranına sahip olduğunu göstermektedir. Ancak, bu sonuçların genellenebilirliği sınırlı kalabilir. Farklı veri setleri veya daha geniş bir çeşitlilikteki hastalık türleri üzerinde test edilmesi, bu bulguların doğruluğunu artırabilir.

Son olarak, derin öğrenme modellerinin eğitiminde kullanılan donanım ve hesaplama kaynaklarının kapasitesi, sınırlayıcı bir faktör olmuştur. Daha güçlü ve geniş kapsamlı donanımların kullanımı, modellerin verimliliğini artırabilir ve daha fazla veriyle eğitilmesi mümkün olabilir.

Bu sınırlamaların gelecekteki alıřmalar iin gz nnde bulundurulması, derin ğrenme yntemlerinin tarım uygulamalarındaki etkinliğini artırmak adına nemli bir adım olacaktır.

KAYNAKLAR

- Acar, O.,(2020).Yapay zekâ fırsat mı yoksa tehdit mi?,*Kriter Yayınevi*, İstanbul.
- Akçelik, V., Atalay, O., & Özen, F. (2021). Duygu analizi ve yapay zeka: Genel bir bakış. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 229-237.
- Akhand, M. A. H., Islam, M. M., & Uddin, M. S. (2021). Emotion recognition from facial expressions using deep learning: A comparative study. *arXiv preprint arXiv:2103.16320*.
- Aksoy, M. S., & Salman, M. S. (2022). Derin Öğrenme Tabanlı Duygu Tanıma: Literatür İncelemesi. *International Journal of Intelligent Systems and Applications in Engineering*, 10(1), 1-8.
- Aktürk, S., & Serbest, K.,(2022). Nesne tespiti için derin öğrenme kütüphanelerinin incelenmesi, *Journal of Smart Systems Research*, 3(2), 97-119.
- Alpaydın, E. (2020). *Makine Öğrenmesi: Temel Kavramlar ve Uygulamalar*. Boğaziçi Üniversitesi Yayınevi.
- Anari, M., Ghorbani, M., Shahriari, H., & Ghorbani, M. A. (2021). Plant Leaf Diseases Detection Using Deep Transfer Learning Model Based on a Combination of Ensemble Technique. *International Journal of Engineering*, 34(11), 2423–2430.
- Ansari, M. A., Singh, D. K., & Singh, K. (2018). Grape leaf disease detection and classification using image processing and machine learning techniques. *International Journal of Advanced Research in Computer Science*, 9(2), 1-6.
- Arıcı, İ., (2023). Artificial intelligence and music education, *Sciences*, 13(3), 579-584.
- Arslan, M. (2022). *Derin Öğrenme ile Hastalık Tespiti*. (Yüksek Lisans Tezi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü).
- Ashok, S., Kishore, G., Rajesh, V., & Suchitra, S. (2019). Tomato plant disease detection using image processing and deep learning techniques. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 8(12), 2278-3075.
- Atalay, M., & Çelik, E.,(2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis, *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Ataseven, B., (2013). Yapay sinir ağları ile öngörü modellemesi, *Öneri Dergisi*, 10(39), 101-115.
- Ateş, A., Güneş, K., & Öz, M. (2020). Akıllı tarım teknolojileri ve uygulamaları. *Türk Tarım ve Doğa Bilimleri Dergisi*, 7(3), 419-432.
- Baireddy, A. (2020). Deep learning for plant disease detection and classification: A case study on tomato leaf diseases. *Journal of Agricultural Technology*, 16(2), 123-145.

- Balta, A., (2018). Makine öğrenmesi teknikleri ile ekolojik verilerin değerlendirilmesi, Yüksek lisans, *Fırat Üniversitesi fen bilimleri enstitüsü*, Elazığ.
- Barbedo, J. G. A. (2018). Detecting potato tuber defects using deep learning for automated visual inspection. *Computers and Electronics in Agriculture*, 154, 84-93.
- Bayuk, M. N., & Demir, B. N., (2019). Endüstri 4.0 kapsamında yapay zekâ ve pazarlamanın geleceği, *International Journal Of Social, Humanities And Administrative Sciences*, 5(19), 781-799.
- Bhagat, A., Lakshmi, J., & Hegde, R. S. (2016). Detection of diseases in bell pepper plants using convolutional neural networks. *Plant Pathology Journal*, 23(4), 120-128.
- Bin, H., Weihai, C., Xingming, W., & Chun-Liang, L., (2017). High-quality face images rusing conditional generative adversarial networks, *arXiv pre print arXiv:1707.00737*.
- Birim, Ş. Ö., (2022). Moda görseli sınıflandırma: düzenleyici teknikler ile evrışimsel sinir ağları uygulaması. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 15(1), 66-76.
- Blasco, J., Aleixos, N., & Moltó, E. (2003). Machine vision system for automatic quality grading of fruit. *Biosystems Engineering*, 85(4), 415-423.
- Brahimi, M., Boukhalfa, K., & Moussaoui, A. (2017). Deep learning for tomato diseases: classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299-315.
- Brock, A., Donahue, J., & Simonyan, K., (2018), Largescale GAN training for high fidelity natural images ynthesis. *arXivpreprint arXiv:1809.11096*.
- Canbolat Göçmen, Z. N., (2022). Sağlık hizmetlerinde yapay zekâ uygulamaları: Yoğun bakım örneği, Doktora Tezi, *İstanbul Medipol Üniversitesi Sosyal Bilimler enstitüsü*, İstanbul.
- Cihan, M., (2020) Hiperspektral görüntüleme yöntemi kullanılarak yenidoğan sağlık durumlarının derin öğrenme metotları ile sınıflandırılması, Yüksek lisans tezi, *Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü*, Konya.
- Ciresan, D. C., Meier, U., Masci, J., Gambardella, L. M., & Schmidhuber, J., (2011). Flexible, high performance convolutional neural networks for image classification. In *Twenty-second international join conference on artificial intelligence*, Galleria 2, 6928 Manno-Lugano, Switzerland, 1237-1242.
- Coşkun, F., & Gülleroğlu, H. D., (2021). Yapay zekânın tarih içindeki gelişimi ve eğitimde kullanılması, *Ankara University Journal of Faculty of Educational Sciences (JFES)*, 54(3), 947-966

- Çalışır, B., (2022). Radyo haberleşmesinde evrişimli sinir ağı kullanılarak yapılan modülasyon sınıflandırması, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(2), 867-877.
- Çeber, B., (2022) Yapay zekâ uygulamalarının halkla ilişkiler aracı olarak kullanımı, Doktora tezi, *Marmara Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul.
- Çekerol, G. S., & Kesler, U., (2021). Artificial Intelligence in marketing, *Journal of Current Researches on Social Sciences*, 11(4), 407-428.
- Çelik, G., & Talu, M. F., (2020). Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi, *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(1), 181-192.
- Çevik, K. K., & Dandil, E. (2012). Yapay sinir ağları için .NET platformunda görsel bir eğitim yazılımının geliştirilmesi. *Bilişim Teknolojileri Dergisi*, 5(1), 19-28.
- Diri, B. (2014). Makine öğrenmesine giriş. Lecture Notes Online. <https://www.ce.yildiz.edu.tr/personal/banud/file/2634/Makine+Ogrenmesi-ML-10.Pdf> 10.06.2024
- Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- Elmas, Ç. (2021). Yapay zekâ uygulamaları (5. baskı). *Seçkin Yayıncılık*.
- Ersoy, E., & Karal, Ö. (2021). Yapay sinir ağları ve insan beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205.
- Ersöz, F., & Çınar, Y. (2021). Veri madenciliği ve makine öğrenmesi yaklaşımlarının karşılaştırılması: Tekstil sektöründe bir uygulama. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 397-414.
- Fang, W., Zhang, F., Sheng, V. S., & Ding, Y. (2018). A method for improving CNN-based image recognition using DCGAN. *Computers, Materials & Continua*, 57(1).
- Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2018). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, 17(9), 2022. <https://doi.org/10.3390/s17092022>
- Garcia, S., Luengo, J., Herrera, F., & Rodriguez, J. (2018). Data preprocessing in data mining. *Cham: Springer International Publishing*.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., & Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27.

- Gürlek, Y., Bozkoyun, E., Ulutürk, M., & Zeyrekgündüz, F. (2023). Yapay zekanın eğitime etkileri ve uygulamaları. *International Journal of Original Educational Research*, 1(1), 25-132.
- 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* (pp. 770-778).
- Hidaka, A., & Kurita, T. (2017, May). Consecutive dimensionality reduction by canonical correlation analysis for visualization of convolutional neural networks. *Proceedings of the ISCIE International Symposium on Stochastic Systems Theory and Its Applications*, 2017, 160-167.
- Hinton, G. E. (2012). A practical guide to training restricted Boltzmann machines. In G. Montavon, G. B. Orr, & K.-R. Müller (Eds.), *Neural networks: Tricks of the trade: Second edition* (pp. 599-619). Springer Berlin Heidelberg.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- Hodges, A. (2012). *Turing'in makinesi: Yapay zeka ve bilgisayar biliminin temelleri*. Princeton University Press.
- Huang, R., Zhang, S., Li, T., & He, R. (2017). Beyond face rotation: Global and local perception GAN for photorealistic and identity preserving frontal view synthesis. *Proceedings of the IEEE International Conference on Computer Vision* (pp. 2439-2448).
- Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1125-1134).
- İçöz, E. (2021). *Covid-19 pandemi sürecinde Milli Eğitim Bakanı'nun Twitter mesajlarının metin madenciliği yöntemiyle incelenmesi [Yüksek lisans tezi]*. Akdeniz Üniversitesi Eğitim Bilimleri Enstitüsü.
- İpek, S. (2019). Yapay zekanın toplum üzerindeki etkisi ve yapay zekâ (AI) filmi bağlamında yapay zekaya bakış. *Uluslararası Ders Kitapları ve Eğitim Materyalleri Dergisi*, 2(2), 203-215.
- İrdem, İ., & Çobanoğlu, S. (2021). Yapay zekânın iç güvenlik yönetimi üzerine yansımaları: Siber güvenlik. *Kamu Yönetimi ve Teknoloji Dergisi*, 3(2), 175-202.
- Jin, Y., Zhang, J., Li, M., Tian, Y., Zhu, H., & Fang, Z. (2017). Towards the automatic anime characters creation with generative adversarial networks. *arXiv preprint arXiv:1708.05509*.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90.

- Kanchana, V., Dixit, A., Sharma, S., & Kavitha, K. (2022). Machine Learning and Deep Learning Techniques for Opinion Mining and Sentiment Analysis. *Proceedings of Second Doctoral Symposium on Computational Intelligence (DoSCI)*, 155-164.
- Karras, T., Aila, T., Laine, S., & Lehtinen, J. (2017). Progressive growing of GANs for improved quality, stability, and variation. arXiv preprint arXiv:1710.10196.
- Kawcher, T., Akter, T., & Uddin, M. S. (2020). Rice Leaf Disease Recognition Using Machine Learning Approach. *International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)*, 416–422.
- Keleş, A., Keleş, A., & Akçetin, E. (2017). Pazarlama alanında yapay zekâ kullanım potansiyeli ve akıllı karar destek sistemleri. *Electronic Turkish Studies*, 12(11).
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2021). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53, 5455-5516.
- Kılıç, N., & Yılmaz, A. (2019). Classification of Plant Leaf Diseases Using Deep Learning Algorithms. In *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-5). IEEE.
- Kızıllı, S. (2019). *Classification of multiple skin diseases using potato images [Yüksek lisans tezi]*. Konya Gıda ve Tarım Üniversitesi.
- Koolagudi, S. G., Krothapalli, R. S., & Rao, K. S. (2018). Emotion recognition from speech: A review. *International Journal of Speech Technology*, 21(1), 1-17.
- Kuchera, J., & Malina, W. (2019). Convolutional layer feature extraction for image classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(1), 100-111.
- Kuş, Z. (2019). *Mikrokanonik optimizasyon algoritması ile konvolüsyonel sinir ağlarında hiper parametrelerin optimize edilmesi [Yüksek lisans tezi]*. Fatih Sultan Mehmet Vakıf Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Kutlugün, M. A., Çakır, M. Y., & Kiani, F. (2017). Yapay sinir ağları ve K-En yakın komşu algoritmalarının birlikte çalışma tekniği (Ensemble) ile metin türü tanıma. 22. Türkiye'de İnternet Konferansı.
- Kuzey, C. (2012). Veri madenciliğinde destek vektör makinaları ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama (Yayımlanmamış Doktora Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4681-4690.

- Li, Y., Liu, S., Yang, J., & Yang, M. H. (2017). Generative face completion. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 3911-3919.
- Liu, X., & Hsieh, C. J. (2019). Rob-gan: Generator, discriminator, and adversarial attacker. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 11234-11243.
- McCarthy, J. (2007). From here to human-level AI. *Artificial Intelligence*, 171(18), 1174-1182.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Metlek, S., & Çetiner, H. (2021). Matlab ortamında derin öğrenme uygulamaları. İksad Yayınevi.
- Metlek, S., & Kayaalp, K. (2020). Derin öğrenme ve destek vektör makineleri ile görüntüden cinsiyet tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(3), 2208-2228.
- Mitchell, T. (1997). *Machine learning*. McGraw Hill.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419. <https://doi.org/10.3389/fpls.2016.01419> 19.02.2024
- Nabiyev, V. V., & Zekâ, Y. (2016). İnsan-bilgisayar etkileşimi. Seçkin Yayıncılık.
- Nagasubramanian, K. (2019). *Strawberry Diseases Identification using Deep Learning Techniques*. (Master's thesis, Dublin, National College of Ireland).
- Omid, M., Noh, H. W., Park, Y. C., & Lee, D. J. (2010). Development of a computer vision system for quality inspection of burley tobacco leaves. *International Journal of Agricultural & Biological Engineering*, 3(4).
- Ongsulee, P. (2017). Artificial intelligence, machine learning and deep learning. 2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE), 1-6. IEEE.
- Özdoğan, O. (2017). Endüstri 4.0: Dördüncü sanayi devrimi ve endüstriyel dönüşümün anahtarları. Pusula Yayıncılık.
- Özkan, İ., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Öztemel, E. (2003). *Yapay sinir ağları*. Papatya Yayıncılık.
- Pang, Y., Sun, M., Jiang, X., & Li, X. (2017). Convolution in convolution for network in network. *IEEE Transactions on Neural Networks and Learning Systems*, 29(5), 1587-1597.

- Pathak, D., Krahenbuhl, P., Donahue, J., Darrell, T., & Efros, A. A. (2016). Context encoders: Feature learning by inpainting. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2536-2544.
- Pehlivan, G., & Güven, Ö. (2019). *Derin öğrenmenin felsefi temelleri (Yüksek Lisans Tezi)*. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Peker, O., Yilmaz, A., & Demir, A. U. (2018). Design of apnea detection interface including time delay neural networks for portable recording devices with three channels. *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4. IEEE.
- Perarnau, G., Van De Weijer, J., Raducanu, B., & Álvarez, J. M. (2016). Invertible conditional GANs for image editing. *arXiv preprint arXiv:1611.06355*.
- Pirim, A. G. H. (2006). Yapay zekâ. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.
- Pulat, M., & Kocakoç, İ. D. (2021). Türkiye'de makine öğrenmesi ve karar ağaçları alanında yayınlanmış tezlerin bibliyometrik analizi. *Yönetim ve Ekonomi Dergisi*, 28(2), 287-308.
- Rabie, A. A. A. (2021). Yarı-nemli iklim koşullarında sürdürülebilir su yönetimi için derin öğrenme kullanılarak referans bitki su tüketiminin tahmin edilmesi (Yüksek Lisans Tezi). *Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü*, Bursa.
- Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- Rázuri, J. V., Karlsson, L., Lindgren, F., & Berggren, M. (2013). Emotional intelligence in human-computer interaction: a review. *IEEE Transactions on Affective Computing*, 4(4), 386-401.
- Russell, S. J., & Norvig, P. (2020). *Yapay zeka: Modern bir yaklaşım (4. baskı)*. Pearson Education.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210-229.
- Sancakdar, A., & Kamer, V. (2021). *Floridi'nin enformasyon felsefesi ve büyük veri (Yüksek Lisans Tezi)*. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Saplıoğlu, K., & Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14-21.
- Sardoğan Doğan, M. (2019). *Bitkilerde görülen hastalıkların derin öğrenme yöntemleriyle tespiti ve sınıflandırılması (Yüksek Lisans Tezi)*. Fen Bilimleri Enstitüsü.

- Sayar, B. (2021). Yapay zekâ ve robot teknolojisinin gazetecilik pratikleri üzerindeki etkileri (Doktora Tezi). Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Sherstinsky, A. (2019). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306.
- Singh, A., Ganapathysubramanian, B., Singh, A. K., & Sarkar, S. (2021). Deep learning for plant stress detection: A review. *Computers and Electronics in Agriculture*, 185, 106137.
- Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. *Advances in neural information processing systems*, 27.
- Şimşek, M. (2022). Makine öğrenmesinin eğitimde kullanımı ile ilgili örnekler. *Eğitim & Bilim 2022-III*, 39.
- Taigman, Y., Polyak, A., & Wolf, L. (2016). Unsupervised cross-domain image generation. arXiv preprint arXiv:1611.02200.
- Terzi, Ö., & Mehmet, K. (2012). Yapay sinir ağları yöntemi ile Göksu nehri'nin akım tahmini. *Uluslararası Teknolojik Bilimler Dergisi*, 4(3), 1-7.
- Tiwari, P., Chauhan, S., Vig, L., Khamparia, A., Gupta, D., & Rodrigues, J. J. (2020). A review on deep learning techniques for video surveillance. *Artificial Intelligence Review*, 53(8), 5889-5924.
- Topçu, C., & Güneş, P. (2024). Bitki hastalıklarını tespitite derin öğrenme: ResNet modelinin etkinliği. *ABMYOD*, 19(69).
- Tutcu, B. (2023). Taşıt kredileri talep tahmininin yapay sinir ağları kullanılarak analiz edilmesi. *Dumlupınar University Journal of Social Science/Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (78).
- Uzun, E. (2007). İnternet tabanlı bilgi erişimi destekli bir otomatik öğrenme sistemi (Doktora Tezi). Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne.
- Ünal, A., & Kılınç, İ. (2020). Yapay zekâ işletme yönetimi ilişkisi üzerine bir değerlendirme. *Yönetim Bilişim Sistemleri Dergisi*, 6(1), 51-78.
- Wang, T. C., Liu, M. Y., Zhu, J. Y., Tao, A., Kautz, J., & Catanzaro, B. (2018). High-resolution image synthesis and semantic manipulation with conditional gans. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 8798-8807.
- Wigderson, A. (2021). *Matematik ve Bilgisayarlar*. Princeton University Press.
- Wu, J., Zhang, C., Xue, T., Freeman, B., & Tenenbaum, J. (2016). Learning a probabilistic latent space of object shapes via 3d generative-adversarial modeling. *Advances in Neural Information Processing Systems*, 29.

- Yakıt, İ., & Külçü, R. (2016). Ktesibios'un su saatinin bilim tarihi ve mekanik açısından değerlendirilmesi. *International Multidisciplinary Congress of Eurasia*, 6-11.
- Yani, M., Budhi Irawan, S. S. M., & Casi Setiningsih, S. M. (2019, May). Application of transfer learning using convolutional neural network method for early detection of terry's nail. In *Journal of Physics: Conference Series* (Vol. 1201, No. 1, p. 012052). IOP Publishing.
- Yaman, O., & Tuncer, T. (2022). Bitkilerdeki yaprak hastalığı tespiti için derin özellik çıkarma ve makine öğrenmesi yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132.
- Yavuz, S., & Deveci, M. (2012). İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Yiğit, A. (2017). *İş süreçlerinde insan görüşünü derin öğrenme ile destekleme [Yüksek Lisans Tez]*. Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne.
- Yu, D., & Deng, L. (2010). Deep learning and its applications to signal and information processing [exploratory dsp]. *IEEE Signal Processing Magazine*, 28(1), 145-154.
- Zaki, A., & Malik, F. M. (2021). Tomato Leaf Diseases Detection Using Fine-Tuned MobileNet V2 Architecture. *International Journal of Engineering*, 34(11), 2431–2438.
- Zhang, H., Sindagi, V., & Patel, V. M. (2019). Image de-raining using a conditional generative adversarial network. *IEEE Transactions on Circuits and Systems for Video Technology*, 30(11), 3943-3956.
- Zhao, Z., Zheng, P., Xu, S., & Wu, X. (2019). *Object detection with deep learning: A review. IEEE transactions on neural networks and learning systems*, 30(11), 3212-3232.
- Zheng, W. Q., Zou, Y. X., & Ritz, C. (2015, April). Spectral mask estimation using deep neural networks for inter-sensor data ratio model based robust DOA estimation. In *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 325-329). IEEE.
- Zhu, Z., He, M., Dai, Y., Rao, Z., & Li, B. (2019). Multi-scale cross-form pyramid network for stereo matching. *2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, 1789-1794. IEEE.