

**T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**YAPAY ZEKA İLE DOMATES
HASTALIKLARININ TESPİTİ VE
SINIFLANDIRILMASI**

Buğra GÜZEL

Danışman: Dr. Öğr. Üyesi Ersan OKATAN

BURDUR, 2024

ETİK KURALLARA UYGUNLUK BEYANI

Burdur Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca **Yüksek Lisans** Tezi olarak sunduğum “**Yapay Zeka ile Domates Hastalıklarının Tespiti ve Sınıflandırılması**” başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

19/01 /2024

(İmza)
Buğra GÜZEL

ÖNSÖZ

Bu araştırma için beni yönlendiren, desteğini ve emeğini hiçbir zaman esirgemeyen değerli tez danışmanım Sayın Dr. Öğr. Üyesi Ersan OKATAN'a teşekkürlerimi sunarım. Burdur Mehmet Akif Ersoy Üniversitesindeki değerli hocalarıma, çalışmamın son haline gelmesindeki katkılarından dolayı teşekkür ederim. Veri kümesi ve tarım alanında yardımlarını esirgemeyen Ziraat Yüksek Mühendisi Sayın Kübra YILDIZ hocama teşekkür ederim.

Son olarak, eğitim hayatımın her aşamasında beni destekleyen aileme sonsuz sevgi ve saygılarımı sunarım.

Ocak, 2024

Buğra GÜZEL

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iii
ÇİZELGELER DİZİNİ	iv
SİMGELER VE KISALTMALAR DİZİNİ	v
ÖZET	vi
ABSTRACT.....	vii
1. GİRİŞ	1
2. GENEL BİLGİLER.....	4
2.1. Domates Hastalıkları.....	5
2.2. Yapay Zeka	8
2.3. Makine Öğrenmesi.....	11
2.3.1. Denetimli Öğrenme	13
2.3.2. Denetimsiz Öğrenme.....	14
2.3.3. Pekiştirmeli Öğrenme.....	14
2.4. Derin Öğrenme.....	14
2.5. Evrişimli Sinir Ağları.....	19
2.5.1. Giriş Katmanı	20
2.5.2. Evrişim katmanı	20
2.5.3. Aktivasyon Fonksiyonu	21
2.5.4. Havuzlama Katmanı.....	21
2.5.5. Seyreltme Katmanı.....	22
2.5.6. Tam Bağlantı Katmanı	22
2.5.7. Yığın Normalleştirme Katmanı.....	22
2.6. Transfer Öğrenme	23
3. MATERYAL VE YÖNTEM	25
3.1. Veri Arttırma.....	26
3.2. Veri Kümesi	26
3.3. Tabakalı Çapraz Doğrulama	28
3.4. Vgg19.....	30
3.5. ResNet101	31
3.6. EfficientNetB3	32
3.7. Performans Metrikleri.....	33
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	36
5. SONUÇ VE ÖNERİLER	46
KAYNAKLAR	48

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Örnek ToBRFV görüntüleri.....	8
Şekil 2.2. Makine öğrenmesi	13
Şekil 2.3. Yapay zeka ve alt dalları.....	17
Şekil 2.4. Yapay nöronun genel yapısı	18
Şekil 2.5. İleri beslemeli-geri yayımlı örnek YSA yapısı.....	18
Şekil 2.6. Temel ESA mimarisi örneği	20
Şekil 2.7. Evrişim işlemi örneği.....	21
Şekil 2.8. YSA’da seyreltme işlemi; a) Seyreltme uygulanmamış, b) Seyreltme uygulanmış	22
Şekil 2.9. Geleneksel makine öğrenmesiyle transfer öğrenme farkı a) Geleneksel makine öğrenmesi b) Transfer öğrenme.....	24
Şekil 3.1. Süreç akış şeması.....	25
Şekil 3.2. Veri kümesindeki rastgele sınıflara ait örnek hastalık görüntüleri.....	28
Şekil 3.3. Tabakalı çapraz doğrulama örneği	29
Şekil 3.4. 1000 sınıf için temel Vgg19 mimarisi	31
Şekil 3.5. Temel artık blok.....	31
Şekil 3.6. ResNet101 temel mimarisi	32
Şekil 3.7. Temel EfficientNetB3 mimarisi	33
Şekil 4.1. Vgg19-Model 1’e ait döneme bağlı kayıp ve doğruluk; a) Kayıp b) Doğruluk	38
Şekil 4.2. ResNet101-Model 5’e ait döneme bağlı kayıp ve doğruluk; a) Kayıp b) Doğruluk.....	39
Şekil 4.3. EfficientNetB3-Model 1’e ait döneme bağlı kayıp ve doğruluk; a) Kayıp b) Doğruluk.....	40
Şekil 4.4. Vgg19-Model 1’e ait hata matrisi.....	41
Şekil 4.5. ResNet101-Model 5’e ait hata matrisi.....	42
Şekil 4.6. EfficientNetB3-Model 1’e ait hata matrisi	42

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Her çapraz doğrulama için veri dağılımları	27
Çizelge 4.1. Eğitim doğrulama ve test aşamalarına ait doğruluk ve kayıp değerleri.....	36
Çizelge 4.2. Vgg19-Model 1’deki sınıflara ait performans değerleri	43
Çizelge 4.3. ResNet101-Model 5’teki sınıflara ait performans değerleri	44
Çizelge 4.4. EfficientNetB3-Model 1’teki sınıflara ait performans değerleri	44
Çizelge 4.5. Çalışmada oluşturulan modelin diğer modellerle karşılaştırması.....	45



SİMGELER VE KISALTMALAR DİZİNİ

AUC	: Eğri Altındaki Alan
Conv	: Evrişim bloğu
DDİ	: Doğal Dil İşleme
DVM	: Destek Vektör Makineleri
ESA	: Evrişimsel Sinir Ağları
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
FRCNN	: Daha hızlı Bölge tabanlı Evrişimsel Sinir Ağı
GAP	: Global Ortalama Havuzlama
IRC	: Ters Artık Bağlantı
Mask RCNN	: Maske Bölge tabanlı Evrişimsel Sinir ağı
MBCon	: Ters çevrilmiş darboğaz evrişim bloğu
TN	: Doğru Negatif
ToBRFV	: Domates Kahverengi Buruşukluk Meyve Virüsü
ToMV	: Domates Mozaik Virüsü
TP	: Doğru Pozitif
TYLCV	: Domates Sarı Yaprak Kıvrıcıklık Virüsü
YSA	: Yapay Sinir Ağları
A1, A2, AN	: Nöron girişleri
f(x)	: Aktivasyon fonksiyonu
W1, W2, WN	: Nöron ağırlıkları
x1, x2, xn	: Bağımsız değişkenler
y	: Nöron çıkışı
θ	: Eğilim (Bias)
Σ	: Toplama fonksiyonu

ÖZET

Yüksek Lisans Tezi

Yapay Zeka ile Domates Hastalıklarının Tespiti ve Sınıflandırılması

Buğra Güzel

Burdur Mehmet Akif Ersoy Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ersan OKATAN

Ocak, 2024

Hızla artan küresel nüfus ile birlikte dünyada gıda talebi sürekli artmaktadır. Tarım alanlarının sınırlı olması ve iklimsel değişiklikler artan bu ihtiyacın karşılanmasında, tarımda verimin artırılması ve kayıpların önlenmesini zorunlu kılmaktadır. Tarımdaki kayıpların önlenmesi için bitki hastalıkları ve zararlılarının, erken ve doğru bir şekilde tespit edilip sınıflandırılması, teknolojinin kullanımı ile mümkündür. Bu amaçla çalışmada, transfer öğrenme yöntemi ile domates yaprak hastalıklarının sınıflandırması yapılmıştır. Çalışma kapsamında Antalya bölgesinden elde edilen domates yaprağına ait 1100 adet ToBRFV (Tomato Brown Rugose Fruit Virus/Domates Kahverengi Buruşukluk Meyve Virüsü) içeren görüntüler veri artırma yöntemleri ile artırılmış, 3070 adet görüntüden oluşan ToBRFV veri kümesi oluşturulmuştur. Oluşturulan ToBRFV veri kümesi, 11 sınıfa ait görüntüler içeren veri artırma uygulanmış “Tomato Disease Multiple Sources” isimli veri kümesiyle birleştirilmiş, daha geniş kapsamlı veri kümesi oluşturulmuştur. 35550 görüntü ve 12 sınıftan oluşturulan bu veri kümesi, tabakalı 5-katlı çapraz doğrulama kullanılarak transfer öğrenme yöntemiyle Vgg19, ResNet101 ve EfficientNetB3 mimarileri kullanılarak 10 dönem eğitilmiş ve performans sonuçları kıyaslanmıştır. Vgg19, ResNet101 ve EfficientNetB3 mimarilerine ait ortalama test doğrulukları sırasıyla %85,02, %96,96 ve %99,27 olmuştur. Her mimarideki 5 çapraz doğrulama sonucu oluşan 15 farklı modelden, EfficientNetB3-Model 1 ise %99,54 ile çalışmadaki en iyi test doğruluğu sonucunu vermiştir. Ayrıca aynı model, ToBRFV dahil 3 sınıfa ait görüntüleri tam doğrulukla sınıflandırmıştır. Elde edilen sonuçlarla farklı domates hastalıklarının da sınıflandırılmasında EfficientNetB3 mimarisinin, güvenilir ve doğru bir şekilde kullanılabileceği görülmektedir.

Anahtar Kelimeler: derin öğrenme, domates hastalıklarının sınıflandırılması, tabakalı çapraz doğrulama, transfer öğrenme

ABSTRACT

M.Sc. Thesis

Detection and Classification of Tomato Diseases with Artificial Intelligence

Buğra Güzel

**Burdur Mehmet Akif Ersoy University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Ersan OKATAN

January, 2024

With the rapidly increasing global population, the demand for food in the world is constantly increasing. Limited agricultural areas and climatic changes make it necessary to increase productivity and prevent losses in agriculture in order to meet this increasing need. Early and accurate detection and classification of plant diseases and pests to prevent losses in agriculture is possible with the use of technology. For this purpose, in the study, tomato leaf diseases were classified using the transfer learning method. Within the scope of the study, images containing 1100 ToBRFV (Tomato Brown Rugose Fruit Virus) of tomato leaves obtained from the Antalya region were increased with data augmentation methods, and a ToBRFV dataset consisting of 3070 images was created. The created ToBRFV dataset was combined with the dataset named "Tomato Disease Multiple Sources", which included images of 11 classes, and a more comprehensive dataset was created. This dataset, created from 35550 images and 12 classes, was trained for 10 epochs using Vgg19, ResNet101 and EfficientNetB3 architectures with the transfer learning method using stratified 5-fold cross validation and the performance results were compared. The average test accuracies of Vgg19, ResNet101 and EfficientNetB3 architectures were 85.02%, 96.96% and 99.27%, respectively. Among 15 different models resulting from 5 cross-validations in each architecture, EfficientNetB3-Model 1 gave the best test accuracy in the study with 99.54%. Moreover, the same model classified images belonging to 3 classes, including ToBRFV, with full accuracy. With the results obtained, it is seen that the EfficientNetB3 architecture can be used reliably and accurately in the classification of different tomato diseases.

Keywords: deep learning, classification of tomato diseases, stratified cross validation, transfer learning

1. GİRİŞ

Tarım, küresel sürdürülebilirliğin temel taşlarından biri olup uzun vadeli ekonomik büyümede önemli bir rol oynamaktadır (Syrquin, 1988). Geçmişte tarımsal faaliyetler gıda ve bitkisel üretimle sınırlıydı. Ancak son yirmi yılda, mahsullerin ve hayvansal ürünlerin işlenmesi, üretimi, pazarlanması ve dağıtımı büyük bir gelişme göstermiştir. Günümüzde tarımsal faaliyetler işsizliği azaltarak insanların temel geçim kaynağı olmakta, ulusal ve uluslararası ticarete büyük katkı sağlamakta ve endüstrideki diğer üretim alanlarına hammadde sağlayarak ekonomiyi geliştirmektedir (Badiane, 2008; Awokuse ve Xie, 2015).

Birleşmiş Milletler Ekonomik ve Sosyal İşler Departmanı verilerine göre dünya nüfusunun 2050’de 9,4 ile 10,1 milyar arasında olacağı öngörülmektedir. Bu durum göz önüne alındığında Birleşmiş Milletler Gıda ve Tarım Örgütü’ne göre 2005-2050 yılları arasında gıda üretiminin %70 artması gerekmektedir. İhtiyaç duyulan bu artışın sadece %10’luk bir kısmı boş bulunan tarım arazilerinin kullanılmasıyla sağlanabilirken %60’lık kısmın, mevcut tarım alanlarının verimliliğindeki artışla sağlanması gerekmektedir. Hızlı nüfus artışı ile birlikte azalan tarım arazileri, tükenen doğal kaynaklar, iklim değişiklikleri ve pazar talebindeki değişimler, tarım sektörünü büyük bir değişime zorlamaktadır (Güzel ve Okatan, 2022).

19. yüzyılda gerçekleşen sanayi devrimi ile birlikte makineler, üretimde insan emeğine belirgin bir katkı sağlamaya başlamıştır. Sanayide başlayan makine kullanımı ile birlikte 20. yüzyılda, tarım da bu gelişmelerden faydalanmaya başlamıştır. Tarım makinelerinin yaygınlaşması, gübre ve pestisit kullanımı gibi gelişmeler ile birlikte 20. yüzyılda artan insan nüfusunun gıda ihtiyacı, sanayi devrimi ve sonrasında gerçekleşen ilerlemeler ile sağlanmıştır. Ayrıca bu sayede, kullanılan insan gücü diğer alanlara yönlendirilerek, küresel anlamda diğer gelişmelere katkı sağlanmıştır (Aceto vd., 2019).

20. yüzyılın sonlarına doğru ise programlanabilir mantıksal denetleyicilerin kullanılmaya başlanması ile Endüstri 3.0 dönemi başlamıştır. Sanayide otomasyon ve bilgi teknolojilerinin öncüsü olan bu gelişmelerin tarım alanında yansımalarının ilk örnekleri; verim izleme, tavsie ve fiyatlandırma sistemleri olarak karşımıza çıkmıştır. 21. yüzyılın başlarında ise Endüstri 4.0 kavramının ortaya çıkmasıyla birlikte yapay zeka, nesnelerin interneti ve büyük veri kavramları hayatımızda önemli bir yer edinmeye başlamıştır. Endüstri 4.0 ile birlikte yaşanan gelişmelerin tarım sektörüne olan ilk yansımaları ise otonom tarım sistemleri, güvenilir gıda zincirleri ve hazır tarım sensör

sistemleri olarak karşımıza çıkmaya başlamıştır. Hızla artan küresel nüfus ile birlikte artan gıda ihtiyacının karşılanması yapay zeka, nesnelerin interneti ve büyük veri gibi yeni teknolojilerin tarım sektörüne entegre edilip yaygın bir şekilde kullanılmasına bağlıdır (Araújo vd., 2021).

Tarım üretiminin kapasitesinin artırılması, birim alandan elde edilen mahsul veriminin artırılması ve kayıpların önlenmesine bağlıdır. Tarımda oluşan kayıpların başında bitki hastalıkları ve zararlıları gelmektedir. Bitki hastalıkları ve zararlıları, tarımsal kayıplara sebep olmakla birlikte insan ve hayvanlarda da hastalıklara sebep olmaktadır. Bitki hastalıkları ve zararlıları kontrolüne yönelik uygulanan geleneksel yöntemler; sınırlı, oldukça zahmetli ve hatalara müsaittir. Ayrıca tarımda hastalık ve zararlı ile mücadelede kullanılan kimyasal ürünler insan ve hayvan sağlığını tehdit etmenin yanı sıra çevreye de çok büyük zararlar verebilmektedir. Teknolojinin de yardımıyla hastalığı ve zararlıyı erken tespit edip yayılmasını önlemek hem ekonomik açıdan hem de iş gücü açısından oldukça önem taşımaktadır (Li vd., 2020).

Tarımda domates dünya çapında en yaygın yetiştirilen ve ekonomik açıdan önemli ürünlerin başında gelmektedir. Ancak gelişen domates endüstrisi, mahsul verimini ve kalitesini etkileyen, dönemsel olarak değişkenlik gösteren hastalık ve zararlılara sürekli maruz kalmaktadır. Uzun süredir yaygın görülen hastalıkların yanı sıra, son yıllarda ülkemizde de görülmeye başlanan Domates Kahverengi Buruşukluk Meyve Virüsü de (Tomato Brown Rugose Fruit Virus/ToBRFV) domates yetiştiriciliğinde büyük kayıplara yol açmaktadır (Fidan vd., 2021). Bu hastalıkların hızlı ve doğru tespiti, geniş çaplı kayıpların önlenmesi açısından büyük önem taşımaktadır. Domates bitkilerindeki geleneksel hastalık tanımlama yöntemleri genellikle tarım uzmanları tarafından yapılan görsel incelemeye dayanır; bu, zaman alıcı, öznel ve insan hatasına açık olabilen bir işlemdir. Modern teknolojilerin tarım sektöründe kullanılmaya başlamasıyla birlikte bitki hastalık ve zararlılarını tespit etmek için yapay zekaya özellikle derin öğrenmeye yönelik ilgi her geçen gün artmaktadır (Jiang vd., 2020).

Makine öğrenmesi yöntemlerinden olan derin öğrenme, görüntü tanıma ve sınıflandırma problemlerinde dikkate değer bir başarı göstermiştir. Son yıllarda, derin öğrenme mimarilerinin özelleşmiş bir türü olan Evrişimsel Sinir Ağları'nın (ESA), görsel problemlerde etkinliği ön plana çıkmaktadır. Yaygın kullanılan ESA mimarilerinde kullanılan yapının ve öğrenilen bilginin aktararak benzer bir problemde kullanılmasıyla ortaya çıkan transfer öğrenme, domates hastalık ve zararlılarının hızlı ve doğru bir şekilde tespit edilip, sınıflandırılması için büyük potansiyel barındırmaktadır (Singh vd., 2023).

Bu tez çalışmasında; Kaggle platformundan elde edilen, domates yaprağına ait yaygın hastalıklardan oluşan, ağırlıklı olarak PlantVillage görüntüleri kullanılmış ve veri arttırımı uygulanmış “Tomato Disease Multiple Sources” isimli veri kümesine, Antalya bölgesinden elde edilen ve veri arttırımı uygulanmış ToBRFV görüntüleri eklenerek 12 sınıflı yeni bir veri kümesi oluşturulmuştur. Oluşturulan yeni veri kümesiyle ToBRFV ve diğer yaygın hastalıkların, transfer öğrenme kullanılarak sınıflandırması yapılmıştır. Tüm sınıfların birbirinden yüksek doğrulukla ayırt edilmesi amaçlanan bu çalışma, aynı zamanda ToBRFV hastalığının derin öğrenme ile sınıflandırılması kapsamında ilk çalışmadır. Ek olarak yapılan çalışmanın; tarım sektöründe, hastalık ve zararlıların doğru sınıflandırılmasıyla birlikte tarımsal üretimin sürdürülebilirliğine katkı sağlayacağı düşünülmektedir.



2. GENEL BİLGİLER

Sürdürülebilir gıda güvenliğine yönelik artan zorunluluk, etkili problem çözümü için yapay zekanın tarıma entegrasyonunu teşvik etmektedir. Son zamanlarda, bitki hastalıklarını ayırt etmek ve sınıflandırmak için yapay zeka algoritmalarının kullanımında, özellikle domates olarak bilinen *Solanum lycopersicum*'a ait çalışmalar her geçen gün artmaktadır. Bu dikkate değer artış, yapay zeka algoritmaları ve bilgisayarlı görme alanındaki çığır açıcı gelişmelerle birlikte veri kullanılabilirliğinin artmasına bağlanabilir. Yapay zekanın bitki hastalıklarının tespitinde ve sınıflandırılmasında uygulanması, mahsul yönetimi uygulamalarını artırma, mahsul kayıplarını azaltma ve gıda güvenliğini iyileştirme konusunda olağanüstü bir potansiyele sahiptir. Bu nedenle, sürdürülebilir gıda üretiminin teşvik edilmesinde ve artan küresel gıda talebinin karşılanmasında yapay zekanın tarımda vazgeçilmezliği açıkça ortadadır (Saranya vd., 2021; Sundararaman vd., 2023).

Domates hastalık sınıflandırması için yapılan bir çalışmada, DVM (Support Vector Machines/Destek Vektör Makineleri) ve Rastgele Orman sığ modelleri ile AlexNet ve GoogleNet ESA mimarileri Plant Village veri kümesinde karşılaştırılmıştır. En yüksek doğruluğa %99,18 ile GoogleNet mimarisi ile ulaşılmıştır (Brahimi vd., 2017).

Rangarajan vd. (2018), Plant Village veri kümesinden seçtiği sağlıklı sınıfı ile birlikte toplam 7 sınıf 13262 görüntü kullandığı çalışmada, AlexNet ve Vgg16 kullanmıştır. Çalışmada AlexNet ile %97,49 doğruluğa ulaşmıştır (Rangarajan vd., 2018).

De Luna vd. (2018) çalışmada kendilerinin geliştirdiği otomatik hastalık yakalama sistemi ile elde edilen 3 hastalık ve sağlıklı sınıfına ait 4923 görüntüsü kullanarak FRCNN (Faster Region Convolutional Neural Network) ile %95,75 sınıflandırma doğruluğuna ulaşmışlardır. Çalışmada %80-%20 eğitim test oranı kullanmışlardır (De Luna vd., 2018).

Bir başka çalışmada ise internetten toplanan 286 görüntüden on çeşit domates hastalığı ve sağlıklı olanı sınıflandırmak için FRCNN kullanılmıştır. Yine aynı çalışmada hastalıklı bölgenin tespiti için Mask RCNN kullanılmıştır. Eğitim, test ve doğrulama oranları sırasıyla %60, %20 ve %20 olarak kullanılmıştır. En iyi doğruluğu bulmak için FRCNN ve Mask RCNN, farklı ESA mimarileriyle birleştirilmiştir. ResNet101 en uzun süre ile en yüksek sınıflandırma doğruluğu vermiştir. Buna karşın MobileNet, daha düşük doğrulukla en hızlı sınıflandıran model olmuştur (Wang vd., 2019).

Agarwal vd. (2020) ise 8 gizli katmandan oluşan hafif bir ESA modeli ile Plant Village veri kümesinden mahsuldeki ayırt edilemeyen 9 hastalık çeşidini sınıflandırmak için kullanılmıştır. 10 farklı sınıf ve 1800 görüntünün kullanıldığı çalışmada en yüksek doğruluk %98,7 ile veri arttırımı uygulanan modelde olmuştur (Agarwal vd, 2020).

Maeda-Gutiérrez vd. (2020) tarafından yapılan çalışmada, transfer öğrenme ile ince ayar yapılarak yaygın ESA mimarilerinden AlexNet, GoogleNet, Inception V3, ResNet18, ve ResNet50 kıyaslanmıştır. Doğruluk, kesinlik, duyarlılık, AUC (Area Under Curve) ve F1 skoru gibi performans parametrelerinin kıyaslandığı çalışmada en iyi model %99,72 AUC ve %99,12 duyarlılık ile GoogleNet olmuştur (Maeda-Gutiérrez vd, 2020).

Verma vd. (2020) ise AlexNet, SqueezeNet ve Inception V3 mimarileri ile Plant Village veri kümesindeki geç yanıklık hastalığının erken, orta ve son aşama olarak şiddetini sınıflandırmaya çalışmışlardır. Çalışma 2342 görüntü ile %80-%20 eğitim-test oranı kullanarak uygulanmıştır. Çalışmada AlexNet, tek başına %89,69 doğruluk sağlarken DVM özellik çıkarımı kullanımı ile %93,40 doğruluğa ulaşmıştır (Verma vd, 2020).

Karthik vd. (2020), artık derin ESA mimarisi ile 120.000 domates yaprağı görüntüsünden üç hastalıklı ve bir sağlıklı kategoriyi sınıflandırmak için kullanılmıştır. Çalışma popüler halka açık veri kümesi PlantVillage ile gerçekleştirilmiştir. Sınıf etiketleri erken yanıklık, geç yanıklık, domates yaprağı küfü ve sağlıklıdır. Yapılan çalışmada genel olarak %98 sınıflandırma doğruluğu elde edilmiştir (Karthik vd, 2020).

Da Costa vd. (2020) tarafından yapılan çalışmada ise domates meyvesinin dış kusurlarını tespit etmek için ResNet101, ResNet50 ve ResNet34 mimarileri kullanılmıştır. 43843 görsel kullanılan çalışmada, eğitim-test-doğrulama oranı sırasıyla %50-%25-%25 olarak kullanılmış olup ResNet50 mimarisi ile %94,60 duyarlılık oranına ulaşmıştır (Da Costa vd, 2020).

2.1. Domates Hastalıkları

Dünya çapında milyonlarca insanı besleyen temel bir ürün olan domates, verimi ve kaliteyi önemli ölçüde azaltabilecek çeşitli hastalıklara eğilimlidir. Bu hastalıklar arasında erken yanıklık (Early Blight), domates bitkilerine saldıran ve bitkinin yapraklarına, saplarına ve meyvelerine ciddi zarar veren bir mantar hastalığıdır. Başlangıçta belirtileri bitkinin alt yapraklarında küçük, dairesel, koyu kahverengi veya ortasında hedef benzeri bir desen bulunan siyah noktalar şeklinde görülür. Ancak hastalık ilerledikçe lekeler büyür ve etkilenen yapraklar sararıp sonunda ölebilir. Ek olarak, gövde

kanserleri oluşabilir ve meyveler enfekte olup çürüyerek daha da fazla zarara neden olabilir (Jones vd, 2014).

Domates bitkilerinin yapraklarına, gövdelerine ve meyvelerine ciddi zarar verebilecek bir diğer mantar hastalığı da geç yanıklıktır (Late Blight). *Phytophthora infestans* sadece domatesleri değil aynı zamanda patatesleri de etkileyen bu hastalığın etkenidir. Yapraklarda, gövdelerde ve meyvelerde suya batırılmış lezyonlar geç yanıklığın ilk belirtileridir; hızla büyür, kahverengiye döner ve beyaz bir küfle kaplanır. Şiddetli vakalarda bitkinin tamamı enfeksiyon kapabilir ve solabilir. Geç yanıklık, yüksek nemin olduğu ortamlarda gelişir ve hastalığın gelişimine uzun süreli yaprak ıslaklığı ve yoğun çiy yardımcı olur (Mulugeta vd, 2019).

Domates septoria yaprak lekesi (Septoria Leaf Spot), domates bitkilerinde önemli yaprak hasarına neden olabilen başka bir mantar hastalığıdır. *Septoria lycopersici*, başlangıçta bitkinin alt yapraklarında küçük, dairesel, kahverengi veya siyah lekeler şeklinde ortaya çıkan bu hastalığın etkenidir. Hastalık ilerledikçe lekeler büyür ve ortası düşerek yaprağa delik görünümü verebilir. Şiddetli vakalarda, sararma ve yaprakların düşmesiyle bitkinin tamamı enfekte olabilir. Septoria yaprak lekesi, serin ve nemli koşulların hastalık gelişimini kolaylaştırdığı, sık yağış alan veya yağmurlama sulama yapılan bölgelerde en yaygın olanıdır. Yüksek nem de katkıda bulunan bir rol oynar (Summers vd., 2014).

Bakteriyel leke (Bacterial Spot), domates bitkilerinin yapraklarını, gövdelerini ve meyvelerini etkileyebilen bakteriyel bir hastalıktır. Bakteriyel lekenin ilk belirtileri bitkinin yaprakları, sapları ve meyveleri üzerinde küçük, suya batırılmış, koyu kahverengi ila siyah lekeler şeklinde ortaya çıkar. Lekeler sarı bir haleyle çevrelenebilir ve çoğu durumda bitkinin tamamı enfeksiyon kapabilir ve yapraklarını dökebilir. Bu hastalık sıcak ve nemli koşullarda gelişir ve en çok sık yağış alan veya yağmurlama yapılan bölgelerde görülür. Yüksek nem aynı zamanda hastalık gelişimine de katkıda bulunur (Jones vd., 2014).

Domates mozaik virüsü (Tomato Mosaic Virus/ToMV), domates yapraklarında, saplarında ve meyvelerinde sarı beneklenme, bodurluk ve malformasyona neden olan viral bir hastalıktır. ToMV semptomlarının şiddeti, virüs türüne ve bitkinin enfekte olduğu aşamaya bağlı olarak değişebilmektedir. ToMV yalnızca sarı beneklenme, bodurluk ve yapraklarda, gövdelerde ve meyvelerde deformasyon gibi yaygın belirtilere neden olmakla kalmaz, aynı zamanda yaprakların kıvrılmasına, kırışmasına ve deforme olmasına da neden olabilir. ToMV'nin yayılması, thrips, yaprak bitleri ve beyaz sinekler

dahil olmak üzere çeşitli böcek vektörleri tarafından kolaylaştırılmaktadır. Bu böceklerin çok sayıda olması daha fazla viral bulaşmaya yol açabilir (Jones vd., 2014).

Domates sarı yaprak kıvrıcıklık virüsü (Tomato Yellow Leaf Curl Virus/TYLCV), domates bitkileri üzerinde zararlı etkileri olabilecek başka bir viral hastalıktır. TYLCV, domates yapraklarının sararmasına, kıvrılmasına ve bodurlaşmasına, ayrıca verimin ve meyve kalitesinin düşmesine neden olur. Aslında TYLCV'nin semptomları yalnızca yaprakların sararmasını, kıvrılmasını ve bodurlaşmasını değil aynı zamanda yaprakların kalınlaşmasını ve kösele dokusunu da içerir. Tatlı patates beyaz sineği (*Bemisia tabaci*) TYLCV'yi yayar ve bu böceklerin büyük bir kısmı, onun daha fazla viral aktarımına katkıda bulunabilir (Sade vd., 2020).

Domates yaprağı küfü (Leaf Mold) ise domates yapraklarının sararmasına, solmasına ve yaprak dökülmesine yol açarak verimin ve meyve kalitesinin düşmesine neden olabilen bir mantar hastalığıdır. Ayrıca yapraklarda grimsi beyaz bir küf de gelişebilir. Yüksek nem ve 60 ila 80 °F arasında değişen sıcaklıklar, serada veya bazı üretim yöntemlerinde daha şiddetli hale gelebilen yaprak küfünün büyümesini kolaylaştırır (Zhao vd., 2022).

İki noktalı kırmızı örümcek akarı (*Tetranychus urticae*/Two Spotted Spider Mite), yapraklarda sararma, noktalanma ve ölümlerin yanı sıra verim ve meyve kalitesinin düşmesine neden olabilen yaygın bir domates bitkisi zararlısıdır. İki noktalı örümcek akarı hasarı aynı zamanda bitkinin yapraklarında ve gövdelerinde ağ oluşumuna da neden olabilir. Sıcak ve kuru hava koşulları, yüksek düzeyde düzenlenmiş ortamlara sahip sera veya yüksek tünel üretim sistemlerinde daha hızlı büyüeyebilen iki noktalı örümcek akarları için idealdir (Osman vd., 2019).

Corynespora yaprak lekesi (*Corynespora cassiicola*/Target Spot), domates bitkilerinin saplarında, yapraklarında ve meyvelerinde dairesel, nekrotik lekelerine neden olan bir mantar hastalığıdır. Bu hastalık, yaprak dökülmesine ve verimde azalmaya neden olabilir ve özellikle sıcak ve nemli koşullarda, önemli yağışların olduğu yerlerde daha şiddetli hale gelebilir. Domates hedef noktasının semptomları arasında meyve, sap ve yapraklar üzerinde sarı bir hale ile çevrelenebilen dairesel, nekrotik lekelerin büyümesi yer alır (Sahu vd., 2019).

Bir başka fungal hastalık olan külleme hastalığı (Powdery Mildew) ise havaların serinlemesi ile alt yapraklardan başlayarak kendini gösteren bir hastalıktır. Açık sarı lekeler ve kül rengi spor tabakası oluşumu ile kendini göstermeye başlayan bu hastalık,

verimde azalma ile yaprak ve meyve kayıplarına neden olur (Yıkılmazsoy ve Çetinkaya, 2022).

Tobamovirüslere ait olan domates kahverengi buruşuk meyve virüsü (Tomato Brown Rugose Fruit Virus/ToBRFV), ticari domates ve biber mahsullerinde ortaya çıkan ve dünya çapında yayılan bir virüstür. Domateste mozaik ve beneklenme, ara sıra yaprak daralması ile sapta, kalikslerde ve yaprak saplarında nekrotik lekeler gibi yaprak belirtileri görülür. Ülkemizde ilk kez 2019 Ocak ayında rapor edilen ToBRFV, bitkilerin veriminde azalmaya neden olmakta ve domates meyvelerinin estetik yapısını bozmaktadır (Fidan vd., 2019; Fidan vd., 2021). ToBRFV hastalığına ait örnek domates yaprağı görüntüleri Şekil 2.1.'de verilmiştir.



Şekil 2.1. Örnek ToBRFV görüntüleri

2.2. Yapay Zeka

Yapay zeka; bilgiyi elde eden ve kullanabilen, bilginin ifade yöntemlerini analiz ederek inceleyen ve insanın entelektüel faaliyetlerini taklit etme becerisini elde etmek için bu yaklaşımları kullanan bir alandır. Yapay zeka, insanın davranışlarını taklit etmek için bilgisayarları kullanır ve bilgisayarları; öğrenme, yargılama ve karar verme gibi insan davranışlarını öğrenmeleri için eğitir. Bilgisayar bilimi, mantık, biyoloji, psikoloji, felsefe

ve diğ er bir ok disiplinin bir araya gelmesiyle ortaya  ıkan yapay zeka ile; konu ma tanıma, g r nt  i leme, Doğ l Dil İ leme (DDİ), otomatik teoremlerin kanıtlanması ve akıllı robotlar gibi uygulamalarda dikkate değ er sonu lar elde edilmi tir. Ayrıca i g c  verimliliğinin artırılması, i g c  maliyetlerinin azaltılması, insan kaynaklarının yapısının optimize edilmesi ve yeni i  talepleri yaratılmasıyla ekonomik ve sosyal kalkınmada vazge ilmez bir rol oynamaktadır (Zhang ve Lu, 2021).

Yapay zekanın alt dallarından biri olan makine  ğrenmesi, yapay zekanın merkezinde yer almakta ve makinelerin verilerden  ğrenmesine ve a ık programlamaya gerek kalmadan zaman i inde performanslarını artırmasına olanak tanımaktadır. Makineler istatistiksel teknikleri ve algoritmaları kullanarak kalıpları tanıyabilir, tahminlerde bulunabilir ve eğitildikleri bilgilere dayanarak kararlar verebilir. Bu  ğrenme ve uyum saėlama yeteneğ i, yapay zeka sistemlerinin s rekli olarak iyile mesine ve geli mesine olanak tanımaktadır (Jiang vd., (2022).

DDİ, yapay zekanın bir diğ er  nemli alanıdır ve makinelerin insan dilini anlamasını ve yorumlamasını saėlar. DDİ sayesinde makineler yazılı ve s zl  dili kavrayabilir. DDİ; sesli asistanlar, sohbet robotları, dil  evirisi, duygu analizi ve bilgi alma gibi bir ok uygulamaya olanak tanır. DDİ'nin ilerlemesi insan-makine ileti imini daha kusursuz ve doğ al hale getirmektedir (Chowdhary ve Chowdhary, 2020).

Bilgisayarla g rme, makinelerin g rsel bilgileri algılamasını ve anlamasını saėlamaya odaklanan yapay zekanın bir ba ka  nemli alt alanıdır. Bilgisayarla g rme algoritmaları, g r nt leri ve videoları analiz edip yorumlayarak makinelerin nesneleri tanınmasına,  r nt leri tespit etmesine ve y z ifadelerini anlamasına olanak tanır. Bilgisayarla g rmenin ilerlemesi; otonom ara lar, g zetim sistemleri, artırılmı  ger eklik ve daha fazlası gibi alanlarda, uygulamaların her ge en g n ilerlemesini saėlamaktadır (Szeliski, 2022).

Yapay zeka uygulamaları t m sekt rlere hızlı bir  ekilde entegre olmaktadır. Saėlık hizmetlerinde yapay zeka; tıbbi te his, ki iselle tirilmi  tedavi planları ve ila  ke fi i in kullanılmaktadır (Gupta vd., 2021). Yapay zeka destekli sistemler,  r nt leri belirlemek ve doğ ru te hisler koymak i in hasta bilgilerinden olu an b y k veri k melerini analiz edebilir. Finans alanında ise yapay zeka; dolandırıcılık tespiti, risk değ erlendirmesi, ticaret ve m  teri hizmetleri i in kullanılmaya ba lanmı tır. Yapay zeka algoritmaları, dolandırıcılık faaliyetlerini tespit etmek, bilin li yatırım kararları vermek ve m  terilere ki iselle tirilmi   neriler sunmak i in b y k miktardaki finansal verileri hızlı bir  ekilde analiz edebilir (Bao vd, 2022).

Siri, Alexa ve Google Assistant gibi yapay zeka destekli sanal asistanlar; ses tanıma, doğal dili anlama ve kişiselleştirilmiş öneriler sunma gibi çeşitli görevleri yerine getirme yetenekleri nedeniyle önemli bir popülerlik kazanmıştır. Bu sanal asistanlar hatırlatıcılar ayarlayabilir, soruları yanıtlayabilir, müzik çalabilir ve hatta akıllı ev cihazlarını kontrol edebilir. Yapay zekadaki sürekli gelişmelerle birlikte sanal asistanlar daha akıllı hale gelmekte ve karmaşık sorguları anlama, doğru ve kişiselleştirilmiş yanıtlar sağlama becerisine sahip olmaktadır (Brill vd., 2018).

Ancak yapay zeka ilerlemeye devam ettikçe etik ve toplumsal zorlukları da beraberinde getirmektedir. Yapay zeka ile ilgili endişeler arasında; otomasyon nedeniyle işten çıkarılma, yapay zeka algoritmalarındaki önyargılar, gizlilik sorunları ve yapay zekanın kötü niyetli kullanıma potansiyeli yer almaktadır. Bu zorlukların üstesinden gelmek ve yapay zekanın toplum üzerindeki etkisi dikkatle değerlendirilerek, sorumlu bir şekilde geliştirilip dağıtıldığından emin olmak çok önemlidir. Yapay zeka sistemlerinde şeffaflığı, adaleti ve hesap verebilirliği sağlamak için etik kurallar ve düzenlemeler gereklidir (Nath ve Sahu, 2020).

Dahası, yapay zeka alanı, devam eden araştırma ve geliştirme yoluyla sürekli olarak gelişmektedir. Araştırmacılar ve bilim adamları, yapay zeka yeteneklerinin sınırlarını zorlamak için sürekli olarak yeni algoritmalar, teknikler ve uygulamalar üzerinde çalışmalar yürütmektedir. Pekiştirmeli öğrenmeden üretken çekişmeli ağlara kadar yapay zeka sürekli olarak gelişmekte ve çeşitli alanlarda uygulamanın yeni yolları aranmaktadır (Goralski ve Tan, 2020).

Ek olarak yapay zeka, teknolojiyle ve etrafımızdaki dünyayla etkileşim şeklimizde devrim yaratma potansiyeline sahiptir. DDİ ve bilgisayar görüşündeki gelişmelerle birlikte yapay zeka destekli sistemler, insan komutlarını ve hareketlerini anlayıp bunlara yanıt vererek teknolojiyi daha kullanışlı ve özelleştirilmiş hale getirebilir (An vd., 2019). Bu, insanlar için daha kişiselleştirilmiş deneyimler yaratma fırsatlarının önünü açmaktadır. Yapay zeka destekli akıllı evler, kişiselleştirilmiş alışveriş deneyimleri ve sanal gerçeklik uygulamaları, yapay zekanın günlük yaşamlarımızı nasıl iyileştirebileceğinin yalnızca birkaç örneğidir (Veselov vd., 2021).

Ayrıca yapay zeka, karar verme süreçlerini büyük ölçüde geliştirme kapasitesine sahiptir. Yapay zeka sistemleri, çok miktarda veriyi analiz ederek ve örüntüleri ve eğilimleri belirleyerek değerli bilgiler ve öneriler sunarak işletmelerin ve kuruluşların bilinçli ve stratejik seçimler yapmasına olanak tanımaktadır. Bu, çeşitli sektörlerde verimliliğin, üretkenliğin ve rekabet gücünün artmasına yol açabilir. Yapay zeka destekli;

analitik, tahmine dayalı modelleme ve karar destek sistemleri, pazarlama, finans, tedarik zinciri yönetimi ve sağlık gibi sektörlerde giderek yaygınlaşmaktadır (Jan vd., 2023).

Ancak yapay zeka daha gelişmiş hale geldikçe ve günlük hayatlarımıza entegre oldukça, etik hususları ele almak ve yapay zeka sistemlerinin sorumlu bir şekilde tasarlanıp kullanılmasını sağlamak hayati önem taşımaktadır. Bu, yapay zeka algoritmalarında şeffaflığın ve hesap verebilirliğin sağlanmasını, yapay zeka ile ilişkili potansiyel önyargıların ve risklerin dikkate alınmasını ve gizlilik ile güvenliğin korunmasını içermektedir. Yapay zekanın insanlığa zararını önleyip faydalı olmasını sağlamak için etik çerçevelerin ve yönergelerin geliştirilmesi çok önemlidir (Müller, 2021; Belk, 2021).

Sonuç olarak yapay zeka hayatımızın çeşitli yönlerinde devrim yaratma potansiyeline sahiptir. Yapay zeka, sağlık hizmetlerinden finansa, sanal asistanlardan karar alma süreçlerine kadar çalışma, etkileşim ve yaşama şeklimizi değiştirmektedir. Ancak yapay zeka konusunda araştırma ve geliştirmeye devam etmek ve aynı zamanda yapay zekanın kullanımını yönetecek etik kuralların ve düzenlemelerin mevcut olmasını sağlamak çok önemlidir. Yapay zekanın gücünden sorumlu bir şekilde yararlanarak, karmaşık sorunları çözmek, yaşam kalitemizi iyileştirmek ve daha adil ve sürdürülebilir bir toplum yaratmak için akıllı makinelerin insanlarla birlikte çalıştığı bir gelecek hedeflenmelidir (Matthews vd., 2021).

2.3. Makine Öğrenmesi

Makine öğrenmesi; bilgisayarların tamamen tüm koşullara göre programlanmasına gerek kalmadan, kendini geliştirerek belirli görevleri öğrenmesine olanak tanıyan yapay zekanın bir alt dalıdır. Verilerden öğrenme ve yeni bilgilere uyum sağlama yeteneği sayesinde makine öğrenmesi, bilgisayarların karmaşık görevleri yerine getirmesine ve akıllı kararlar almasına olanak tanır (Zhou, 2021). Yeni teknikleri keşfetmeye ve geliştirmeye devam ettikçe makine öğrenmesinin olanakları neredeyse sınırsızdır. Alandaki çalışmalar, otonom bir şekilde; örüntü tanıma, tahmin yapma ve deneyim yoluyla öğrenme amaçlarıyla algoritmalar ve modeller geliştirme üzerinde yoğunlaşmıştır. Makine öğrenmesi temelde verilerden öğrenmeye dayanır. Öğrenme algoritmaları veri kümeleri üzerinde eğitilerek, veri kümelerindeki örüntüler ve temel ilişkiler ortaya çıkarılır. Veri kümesinin kalitesi ve büyüklüğü, modelin genelleme yeteneğini büyük ölçüde etkiler. Eğitim aşamasında öğrenme algoritması, hataları minimuma indireyecek ve doğruluğu maksimuma ulaştıracak şekilde parametreleri

ayarlar. Ardından eğitilen model hiç görülmemiş yeni veriler-durumlar üzerinde tahminlerde bulunur veya kararlar alır (El Naqa ve Murphy, 2015; Alpaydin, 2021).

Makine öğrenmesi; bilgisayar bilimi, istatistik ve yapay zeka gibi alanların birleşimi ile oluşmuş olup, bilgisayarların verilerden öğrenmesini ve açıkça programlanmadan tahminler veya kararlar almasını sağlamak için algoritmik ve istatistiksel yöntemleri birleştirir. Büyük ve karmaşık veri kümelerinden kalıpları ve yaklaşımları ortaya çıkarma yeteneği nedeniyle son yıllarda önemli bir ilgi ve popülerlik kazanmıştır (Wang vd., 2016).

Makine öğrenmesinin temel özelliklerinden biri, makine öğrenmesi modelinin örneklerle maruz kaldığı ve onlardan kalıpları veya ilişkileri öğrendiği eğitim verilerinin kullanılmasıdır. Model, verileri analiz ederek gizli kalıpları belirleyebilir ve yeni, görünmeyen veriler üzerinde doğru tahminler veya kararlar verebilir. Bu deneyimden öğrenme yeteneği, makine öğrenimini geleneksel programlama yöntemlerinden ayırır (Choi vd., 2020).

Makine öğrenmesinin çok geniş uygulama alanları vardır. Bilgisayarla görme alanında; görüntü ve video tanıma, nesne tespiti ve görüntü bölütleme için makine öğrenmesi teknikleri kullanılmaktadır. DDİ'de makine öğrenmesi ise; duygu analizi, metin sınıflandırma, makine çevirisi ve konuşma tanıma gibi görevler için kullanılır. Makine öğrenmesi ayrıca öneri sistemlerinde, dolandırıcılık tespitinde ve otonom araçlarda da önemli bir rol oynamaktadır. Son zamanlarda sağlık, finans, üretim, ulaşım, eğlence ve çevre analizlerinde kullanılmaya başlanmıştır (Bertolini vd., 2021; Sarker, 2021).

Makine öğrenmesinin endüstrilerde devrim yaratma ve karar verme süreçlerini iyileştirme potansiyeli çok büyüktür. Verilerin ve hesaplamalı algoritmaların gücünden yararlanan makine öğrenmesi, değerli bağlantı ve yapıları ortaya çıkarabilir, doğru tahminler yapabilir ve karmaşık görevleri otomatikleştirebilir. Süreçleri optimize ederek, verimliliği artırarak ve veriye dayalı karar almayı mümkün kılarak; sağlık, finans, üretim, ulaşım ve eğlence gibi çeşitli endüstrileri dönüştürme yeteneğine sahiptir (Rai vd., 2021).


Makine öğrenmesi alanı ilerlemeye devam ettikçe, araştırmacılar ve uygulayıcılar daha karmaşık ve zorlu sorunların üstesinden gelmek için sürekli olarak yeni teknikler ve algoritmalar geliştirmektedir. Makine öğreniminin bir alt alanı olan derin öğrenme, verilerden hiyerarşik temsilleri öğrenme yeteneği nedeniyle son yıllarda büyük ilgi görmekle birlikte görüntü tanıma, DDİ ve otonom sürüş gibi alanlarda çığır açıcı gelişmelere yol açmıştır (Johri vd., 2020).

Ayrıca makine öğrenmesi tek bir yaklaşım veya yöntemle sınırlı değildir. Makine öğrenmesinde üretken modeller, ayrımcı modeller ve topluluk yöntemleri dahil olmak üzere farklı yaklaşımlar mevcuttur. Bu yaklaşımların her biri farklı problemlere ve veri türlerine uygulanabilmektedir (Harshvardhan vd., 2020).

Dahası, makine öğrenmesi yalnızca algoritmalar ve modellerle ilgili değil aynı zamanda tüm işlem hattı ve iş akışıyla da ilgilidir. Veri ön işleme, özellik mühendisliği, model eğitimi, model değerlendirme ve düzenleme gibi adımları içerir. Makine öğrenmesi modelinin başarısını garantilemek için bu adımların her birinde dikkatli bir değerlendirme ve uzmanlık gerekir (Paleyes vd, 2022).

Sonuç olarak makine öğrenmesi, endüstrilerde devrim yaratma ve günlük yaşamlarımızı iyileştirme potansiyeline sahip, heyecan verici ve hızla gelişen bir alandır. Verilerden öğrenme ve yeni bilgilere uyum sağlama yeteneği sayesinde makine öğrenmesi, bilgisayarların karmaşık görevleri yerine getirmesine ve akıllı kararlar almasına olanak tanır. Makine öğreniminin sınırlarını zorlamaya devam ettikçe fırsatlar ve olanaklar sonsuzdur.

Her birinin kendine has güçlü yönleri ve uygulamaları olan çeşitli türde makine öğrenmesi algoritmaları vardır. Makine öğrenmesi Şekil 2.2.'de gösterildiği gibi, denetimli, denetimsiz ve pekiştirmeli öğrenme olarak üç ana grupta incelenebilir.



Şekil 2.2. Makine öğrenmesi

2.3.1. Denetimli Öğrenme

Denetimli öğrenme, giriş verilerine karşın çıkış verilerinin etiketlendiği makine öğrenmesi yöntemidir. Algoritma en optimum modeli oluşturarak bağımsız

değişkenlerden, bağımlı değişkeni tahmin etmeye çalışır. Böylece oluşturulan model yardımıyla, eğitimde var olmayan koşullar üzerinde bile tahmin yapılabilmesi olanaklı hale gelir. Sınıflandırma ve regresyon problemlerine genellikle denetimli öğrenme uygulanırken, görüntü-ses tanıma ve sayısal tahmin görevleri denetimli öğrenmeye örnek olarak verilebilir. Denetimli öğrenme; görüntü sınıflandırma, e-posta spam filtreleme ve fiyat tahmin etme gibi görevlerde yaygın olarak kullanılır (Jiang vd., 2020).

2.3.2. Denetimsiz Öğrenme

Denetimsiz öğrenmede, algoritma etiketsiz verilerle bariz bir denetim olmadan kalıpları ve grupları tanımlamaya çalışır. Kümeleme, ilişkilendirme ve boyut indirgeme problemlerinde genellikle denetimsiz öğrenme uygulanmaktadır. Yaygın olarak müşteri bölümlendirme, anormallik tespiti ve öneri sistemleri gibi görevlerde kullanılırlar (Alloghani vd., 2020).

2.3.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, otonom bir iş yapılması gereken sistemlerde kullanılır. Pekiştirmeli öğrenmede bulunduğu çevreyi algılayan bir ajan bulunmaktadır. Ajan bulunduğu çevreyle etkileşime girerek eylemde bulunur ve her eylem için ödül-ceza durumlarını optimize etmeye çalışır. Diğer öğrenme yöntemlerinden farklı olarak pekiştirmeli öğrenmede, bilinmeyen durumları keşfetme ve bilinen yola yönelme denge halindedir. Oyun ve robotik sektörlerinde kullanımı ile ön plana çıkmaktadır (Vázquez-Canteli ve Nagy, 2019).

2.4. Derin Öğrenme

Makine öğrenmesinin alt alanı olan derin öğrenme, yapay sinir ağlarının karmaşık görevleri yerine getirecek şekilde eğitilmesinde güçlü bir yaklaşım olarak ortaya çıkmıştır. Derin öğrenme modelleri, insan beyninin yapısını ve işlevini taklit ederek bilgisayarla görme, DDİ, konuşma tanıma ve daha fazlası dahil olmak üzere çeşitli alanlarda olağanüstü yetenekler sergilemiştir (Dong vd., 2021).

Bilgisayarla görmede derin öğrenme, görsel bilgiyi anlama ve yorumlama şeklimizde büyük gelişmelere yol açmıştır. Derin sinir ağları aracılığıyla modeller, görüntülerdeki nesneleri benzeri görülmemiş bir doğrulukla tanımayı ve sınıflandırmayı öğrenebilmektedir. Bu, derin öğrenme algoritmalarının yayaları, araçları ve trafik işaretlerini tespit edip tanımlayabildiği, daha güvenli sürüş deneyimleri sağlayan otonom

araçlar gibi uygulamaların yanı sıra, tıp ve tarımsal hastalık tespitinde çok önemli bir rol oynamış ve taramaları inanılmaz bir hassasiyetle analiz ederek hastalıkların erken tespitini ve teşhisini mümkün kılmıştır. Dahası, derin öğrenme, artırılmış gerçeklik alanının geliştirilmesinde, gerçek zamanlı nesne tanıma ve izlemenin yanı sıra gerçekçi sanal nesneler ve ortamlar oluşturmada da etkili olmuştur (Kelleher, 2019).

DDİ alanında derin öğrenme, insan benzeri metinleri anlama ve üretme yeteneğimizi geliştirmeye devam etmektedir. Derin sinir ağları kullanılarak oluşturulan dil modelleri artık kelimelerin ve cümlelerin ardındaki anlamı kavrayabilmekte ve bu da makine çevirisi, duygu analizi, sohbet robotu teknolojileri ve daha pek çok alanda ilerlemelere yol açmaktadır. Derin öğrenme algoritmaları, makinelerin insanlarla daha doğal ve tutarlı bir şekilde iletişim kurmasını mümkün kılarak insan ve makine arasındaki boşluğu doldurduğu söylenebilir. Bu, otomatik müşteri hizmetlerini, dil derslerini ve hatta yaratıcı yazarlık ve hikaye anlatımı gibi alanlarda ilgi çekici anlatıların oluşturulmasını kolaylaştırmaktadır (Eisenstein, 2019; Torfi vd., 2020).

Konuşma tanıma, derin öğrenmenin önemli ilerlemeler kaydettiği başka bir alandır. Modeller, derin sinir ağlarını çok miktarda konuşma verisiyle eğiterek konuşulan kelimeleri doğru bir şekilde yazıya dökebilir ve ses kontrollü sistemleri etkinleştirebilir. Bu, teknolojiyle etkileşim şeklimizde; sanal asistanlarla zahmetsizce iletişim kurmamıza, metin yazdırmamıza ve çeşitli uygulamalarda sadece sesle gezinmemize olanak sağlamıştır. Derin öğrenmedeki gelişmelerle birlikte konuşma tanıma, sesli asistanların ayrılmaz bir parçası haline gelmektedir. Bu, onları engelli bireyler için daha erişilebilir ve kullanıcı dostu hale getirmenin yanı sıra günlük hayatta kesintisiz ses tabanlı etkileşimleri kolaylaştırmaktadır (Kamath vd., 2019).

Derin öğrenme modellerini etkili bir şekilde eğitmek için genellikle önemli miktarda etiketli veri ve hesaplama kaynağı gerekmektedir. Bununla birlikte, büyük veri kümelerinin varlığı ve bilgi işlem gücündeki ilerlemeler, derin öğrenme modellerinin geliştirilmesini ve eğitilmesini daha erişilebilir ve verimli hale getirmiştir. Ayrıca, bulut bilişimin ortaya çıkışı ve ölçeklenebilir altyapının kullanıma sunulmasıyla birlikte, derin öğrenme çok büyük ölçekte gerçekleştirilebilir, büyük miktarlarda verinin işlenmesine olanak sağlanır ve yenilikçi uygulamaların geliştirilmesi hızlandırılabilir (Ghosh ve Grolinger, 2020).

Başarılarına rağmen derin öğrenme bazı zorluklarla ve sınırlamalarla da karşı karşıyadır. Önemli zorluklardan biri, derin öğrenme modellerinin eğitim ve kullanma için gerekli olan hesaplama gücü ve işlem maliyeti ihtiyacıdır. Bu sınırlama, kaynakların


kısıtlı olduğu ortamlarda derin öğrenmenin yaygın olarak kullanılmasını engelleyebilir. Ek olarak, derin öğrenme modelleri genellikle kara kutu olarak kabul edilir ve karar verme süreçlerini yorumlamayı ve açıklamayı zorlaştırır. Bu şeffaflık eksikliği, özellikle sağlık ve finans gibi yorumlanabilme ve hesap verebilmenin çok önemli olduğu alanlarda sorun yaratabilir. Bu zorlukların üstesinden gelmek, model optimizasyonu için yenilikçi teknikler, kaynak açısından verimli algoritmalar ve derin öğrenme modellerinin iç işleyişine ışık tutan açıklanabilir yapay zeka alanlarında yorumlanabilirlik yöntemleri geliştirmek için disiplinler arası iş birliklerini ve sürekli araştırmaları gerektirmektedir (Choi vd., 2020).

Bununla birlikte, bu zorlukların üstesinden gelmek ve derin öğrenme modellerinin yorumlanabilme ve açıklanabilme kapasitelerini arttırmak için teknikler geliştirmek gereklidir. Bu modellerin iç işleyişinin kavranarak güvenin artırılması, karar verme süreçlerinin tam olarak anlaşılması ve derin öğrenme teknolojisinin etik ve sorumlu bir şekilde kullanılmasının sağlanması büyük önem arz etmektedir. Bu, verilerdeki önemli özellikleri vurgulayan dikkat mekanizmalarının geliştirilmesi, model tahminlerinin ardındaki mantığı ortaya çıkarmayı amaçlayan açıklanabilirlik yöntemleri ve hesaplama yükünü azaltarak verimliliği artıran model sıkıştırma ve transfer öğrenme tekniklerinin yaygınlaşması ile mümkündür (Helbing, 2019; Burkart ve Huber, 2021).

Son yıllarda derin öğrenme araştırmalarında kayda değer gelişmeler yaşanmaktadır. Odaklanılan alanlardan biri, daha az hesaplama kaynağı gerektiren daha verimli algoritmaların ve mimarilerin geliştirilmesidir. Bu, performanstan ödün vermeden derin öğrenme modellerinin boyutunu ve karmaşıklığını azaltmayı amaçlayan model sıkıştırma gibi teknikleri içerir. Başka bir araştırma alanı olan transfer öğrenme ise, bir görevden öğrenilen bilgiyi diğer bir görevdeki performansı artırmak için kullanmayı amaçlayan alternatif eğitim yöntemlerini içerir. Bu gelişmeler, kaynakların kısıtlı olduğu ortamlar da dahil olmak üzere çok çeşitli uygulamalar için derin öğrenmeyi daha erişilebilir ve pratik hale getirme potansiyeline sahiptir (Iman vd., 2023).

Bir başka araştırma alanı da derin öğrenmenin pekiştirmeli öğrenme gibi diğer yapay zeka dallarıyla birlikte kullanılmasını içerir. Bu yaklaşım, derin öğrenme modellerinin deneme yanılma yoluyla öğrenebildiği ve istenen sonuçlara ulaşmak için davranışlarını optimize edebildiği karmaşık karar verme görevlerinde umut verici sonuçlar vermiştir. Derin öğrenmenin pekiştirmeli öğrenmeyle entegrasyonu; otonom robot bilimi, kişiselleştirilmiş tıp ve akıllı öneri sistemleri gibi alanlarda ilerleme


potansiyeline sahiptir (Kiran vd., 2021). Yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki ilişki Şekil 2.3.'te gösterilmiştir (Shinde ve Shah, 2018).



Şekil 2.3. Yapay zeka ve alt dalları


Derin öğrenmenin temelinde, insan beynindeki karmaşık nöronlardan ilham alınan, matematiksel temele dayanan YSA (yapay sinir ağları) bulunmaktadır. Birbirine bağlı nöronlardan veya düğümlerden oluşan YSA, verilerdeki karmaşık kalıpları ve yapıları öğrenerek makinelerin karar almasını sağlar. Bir YSA yapısının derinliği, sahip olduğu katman sayısına bağlıdır. Tek katmanlı bir YSA yapısı, bağımlı değişkenler ile bağımsız değişken arasında genelde yüzeysel ilişki kurabilirken, nöron sayısı fazla olan ve daha derin YSA yapıları, çok karmaşık ilişkileri dahi kavrayabilmektedir. Ancak optimize edilmemiş derin YSA yapıları; tahmin doğruluğu, işlem süresi ve işlem maliyeti açısından sorunlar yaratabilmektedir (Rusk, 2016).

Derin öğrenmede nöron ve katman sayısı ile birlikte aktivasyon fonksiyonu da çok önemlidir. Aktivasyon fonksiyonu, YSA yapısındaki her nöronun çıkışını belirleyen matematiksel fonksiyonlardır. Aktivasyon fonksiyonlarının amacı, veri yapısı içindeki doğrusal olmayan yapıları ortaya çıkararak veri içindeki karmaşık kalıpları ve ilişkileri modellenmesini sağlamaktır (Szandala, 2021). YSA'nın içerdiği bir nöronun yapısı Şekil 2.4.'te verilmiştir.



Şekil 2.4. Yapay nöronun genel yapısı

Nöronda girişler ($A_1, A_2 \dots A_N$), ağırlıklar ($W_1, W_2 \dots W_N$) ile çarpılır ve eğilim (bias- θ) ile birlikte tüm değerler toplanarak aktivasyon fonksiyonuyla ($f(x)$) işleme tabi tutulur. İşlem sonucu oluşan çıkış değeri (y), YSA sonucunda elde edilen tahmin değeri olabileceği gibi bir sonraki katmanın girişi de olabilir. Derin YSA yapıları ise çok sayıda nöron ve katmanların bir araya gelmesiyle oluşmaktadır. (Schmidhuber, 2015). İleri beslemeli-geri yayımlı bir derin YSA yapısı örneği Şekil 2.5.'te verilmiştir.



Şekil 2.5. İleri beslemeli-geri yayımlı örnek YSA yapısı

Derin YSA yapıları, giriş katmanında bulunan bağımsız değişkenler ($x_1, x_2 \dots x_n$), gizli katmanlardaki nöronlarda işleme uğrayarak çıkış değeri (y) bağımlı değişkenine ulaşmaya çalışır. Çıkış değeri regresyon problemi için sayısal bir değer olabileceği gibi

sınıf etiketi de olabilir. Gizli katmandaki nöron ve katman sayıları ağıın derinliğine göre değişebilmektedir.

Sonuç olarak derin öğrenme, yapay zeka alanını dönüştürerek makinelerin başarabileceklerinin sınırlarını zorlamaktadır. Verilerden karmaşık temsilleri öğrenme yeteneği, bilgisayarlı görme, DDİ, konuşma tanıma ve diğer alanlarda çıkır açan gelişmelerin yolunu açmaktadır. Derin öğrenmenin sınırlamaları olsa da devam eden araştırma ve geliştirme çabaları, bu zorlukların üstesinden gelme ve teknolojinin geleceğini şekillendirmede derin öğrenmenin önemini ortaya koymaktadır. Derin öğrenme alanında yeni keşiflere devam ettikçe, günlük yaşamlarımız ve çevremizdeki dünya üzerinde derin bir etki yaratacağı düşünülmektedir.

2.5. Evrişimli Sinir Ağları


ESA, evrişim yapılarıyla verilerden özellikler çıkarabilen bir tür ileri beslemeli derin YSA'dır. ESA, çoğunlukla görüntü sınıflandırma ve tanıma görevleri için kullanılan bir tür ileri beslemeli derin YSA yapısıdır. İnsan beyninin görsel işleme yeteneklerini taklit edecek şekilde tasarlanmıştır. ESA'ların en büyük avantajlarından biri, giriş verilerinden otomatik olarak özellikleri çıkarma ve öğrenme yetenekleridir. Bu ESA'ların, manuel özellik mühendisliği ihtiyacını ortadan kaldırarak karmaşık görsel görevleri yerine getirmede oldukça etkili olmasını sağlar (Albawi vd., 2021).

ESA'lar; görüntü sınıflandırma, nesne algılama ve görüntü bölümlendirme gibi çeşitli görevlerle birlikte görüntü oluşturma ve stil aktarımı gibi daha gelişmiş görevlerde bile yüksek performanslara ulaşmaya başlamıştır. Sürücüsüz arabalar, tıbbi görüntü analizi, yüz tanıma gibi uygulamalarla birlikte sanat gibi yaratıcı alanlarda başarıyla kullanılmaktadır (Krichen, 2023). ESA'ların etkinliklerinin yanında ölçeklenebilirlikleri de önemli bir başka özelliktir. Bu sayede büyük ölçekli veri kümeleri üzerinde eğitilebilirler ve birden fazla GPU arasında kolayca paralelleştirilebilirler. Bu da onları yüksek performanslı bilgi işlem ortamları için uygun hale getirmektedir (Khan vd., 2019).

ESA'lar, geniş bir veri kümesi üzerinde eğitim vererek çeşitli kalıpları ve nesneleri tanımayı öğrenebilir ve zaman içinde performansını artırabilir. Biyolojik nöronları taklit eden ESA nöronları, çeşitli özelliklere yanıt verebilen farklı reseptörleri temsil eder. Aktivasyon fonksiyonları ise yalnızca belirli bir eşik aşan sinirsel elektrik sinyallerini, bir sonraki nörona ileten matematiksel fonksiyonları ifade etmektedir. Ayrıca ESA mimarilerindeki kayıp fonksiyonları, hatayı belirleyip öğrenmeyi optimize etmek için büyük öneme sahiptir. Bunların yanında ESA mimarilerinde, özellikleri indirgeyerek

kritik öneme sahip özelliklerin ön plana çıkmasını, gereksiz özelliklerin elenmesini sağlayan katmanlar da bulunmaktadır. Bu sayede modelin maksimum doğruluğa, daha az işlem maliyetiyle daha kısa sürede ulaşması sağlanır (Li vd., 2021).

Şekil 2.6.'daki örnekte görüldüğü gibi temel ESA mimarisi, özelleşmiş katmanlara sahip derin YSA yapılarından oluşmaktadır. Giriş, evrişim, havuzlama, tam bağlantı ve sınıflandırıcı katmanları ESA mimarilerinin temellerini oluşturur.



Şekil 2.6. Temel ESA mimarisi örneği


2.5.1. Giriş Katmanı

ESA'nın yaygın kullanıldığı görüntü işlemede giriş katmanı, ağın bir görüntünün ham piksel değerlerini aldığı ilk katmandır. Giriş katmanındaki her nöron, görüntüdeki bir piksele karşılık gelir ve bu nöronların değerleri, karşılık gelen piksellerin yoğunluğunu veya renk bilgisini temsil eder. Giriş katmanı, görüntü tanıma gibi görevlerde önemli olan giriş verilerinin uzamsal yapısının yakalanmasında çok önemli bir rol oynar. ESA'da giriş katmanından sonra gelen evrişim, havuzlama ve tam bağlantı gibi katmanlar, giriş katmanı tarafından öğrenilen özellikler üzerine kuruludur (Ketkar vd., 2021).

2.5.2. Evrişim katmanı

Görüntünün özellikleri bu katmanda çıkarıldığı için evrişim katmanı aynı zamanda özellik çıkarma katmanı olarak da adlandırılır. Evrişim katmanında giriş verilerine özellik çıkarma işlemi için filtreler uygulanır. Uygulanan her bir filtre, giriş görüntülerindeki belirli özellik ve örüntüleri tanımak için tasarlanmıştır. Genellikle ilk katmanlarda uygulanan filtreler yazıları, sınırları ve basit yapıları algılamak için kullanılırken bazı filtreler ağ derinleştikçe görüntülerdeki en karmaşık yapıları bile algılayabilmektedir.

Filtre uygulama işleminde, bir önceki katmandan gelen matrise, çekirdek (kernel) de denilen filtreye ait matris uygulanmasıyla yeni bir matris ortaya çıkarılır. Evrişim işlemi olarak adlandırılan bu işlemin temel bir örneği Şekil 2.7.'de verilmiştir.



Şekil 2.7. Evrişim işlemi örneği (Zhang vd., 2023)

Verilen örnekte 3x3 girdi matrisine 2x2 boyutlu çekirdek (filtre) uygulanarak 2x2 çıktı matrisi elde edilmiştir. Çıktı matrisini elde ederken girdi ve çekirdek matrisinin ilgili terimleri çarpılarak toplanır ve çıktı matrisinde ilgili alana yazılır. Çıktı matrisindeki ilk terim için $(0 \times 0 + 1 \times 1 + 3 \times 2 + 4 \times 3 = 19)$ olarak bulunur. Ardından filtreyi girdi matrisi üzerinde sağa ve aşağı kaydırarak tüm girdi matrisi üzerinde aynı işlem uygulanarak çıktı matrisi oluşturulur (Zhang vd., 2023).

Burada girdi matrisi bir önceki katmandan gelen belirli işlemlere uğramış matris olabileceği gibi, doğrudan da giriş katmanından gelen görüntü matrisi olabilir. Çıktı matrisi ise aktivasyon fonksiyonu uygulandıktan sonra, özellik seçimi için havuzlama katmanına gönderilir.

2.5.3. Aktivasyon Fonksiyonu


ESA'larda aktivasyon fonksiyonu en önemli parametrelerin başında gelmektedir. Evrişim ve tam bağlantı katmanlarından sonra çıktıya uygulanarak doğrusallığı azaltır ve veri içerisindeki doğrusal olmayan karmaşık yapıların öğrenilmesini sağlar. Aktivasyon fonksiyonları aynı zamanda bir nöronun aktif olup olmayacağına karar veren fonksiyonlardır. Relu, Tanh, Sigmoid, Softmax ve Swish gibi aktivasyon fonksiyonları ESA'larda sıkça kullanılmaktadır (Varshney ve Singh, 2021).

2.5.4. Havuzlama Katmanı

ESA'larda genelde evrişim katmanını, havuzlama katmanı takip eder. Havuzlama katmanının görevi, evrişim katmanı tarafından çıkarılan özellik haritalarının boyutlarını azaltarak ağın hesaplama maliyetini ile karmaşıklığını azaltmak ve ağı ezber yapmasını önlemektir. Havuzlama katmanı, ağ içerisinde öğrenilebilir parametre içermemekle birlikte tam bağlantı katmanı ile evrişim katmanını da birbirine bağlar. Genellikle maksimum havuzlama, ortalama havuzlama ve global ortalama havuzlama olarak üç farklı şekilde kullanılmaktadır (Goodfellow vd., 2016).

2.5.5. Seyreltme Katmanı

Seyreltme işlemi, ESA'lar ve diğer sinir ağı mimarilerinde sıklıkla kullanılan düzenleme tekniğidir. Seyreltme işlemindeki amaç eğitim sırasında bazı nöronları eğitim sırasında kapatarak öğrenmeyi geliştirme, yeni veriye hızlı adapte olmayı ve ezberi önlemeyi sağlar. Genellikle seyreltme oranı 0,2 ile 0,5 aralığında kullanılır. (Srivastava vd., 2014). Yapılan çalışmada tüm modellerde sınıflandırmadan hemen önce 0,45 oranında seyreltme kullanılmıştır. Seyreltme işleminin örneği Şekil 2.8.'de verilmiştir.



Şekil 2.8. YSA'da seyreltme işlemi; a) Seyreltme uygulanmamış, b) Seyreltme uygulanmış (Srivastava vd., 2014)

2.5.6. Tam Bağlantı Katmanı

Tam bağlantı katmanında (Fully Connected/Dense Layer) her nöron, bir önceki katmandaki tüm nöronlara bağlıdır. ESA'lar için tam bağlantı katmanı öğrenilen özelliklere bağlı son matematiksel işlemleri yapmak ve sınıf tahminlerini yapmak için genellikle evrişim ve havuzlama katmanlarını takiben ağın sonunda bulunur (Basha vd., 2020).

2.5.7. Yığın Normalleştirme Katmanı


Yığın normalleştirme, ESA'larda eğitim doğruluğunu ve öğrenme hızını arttırmak için uygulanan bir tekniktir. Yığın normalleştirme, değerler arasındaki uçurumu önlemek ve öğrenmeyi optimize etmek için aktivasyon fonksiyonu uygulanmadan önce katmanın girişine uygulanır. Bu katmanlar, derin öğrenme yöntemleri ile birlikte özellikle

ESA’larda ağın performansını ve istikrarını sağlayan önemli bir bileşen haline gelmiştir (Ioffe ve Szegedy, 2015).

2.6. Transfer Öğrenme

Son yıllarda derin öğrenme, özellikle veri kümelerinin doğrusal olmaması gibi bir dizi zorlu ve ilginç problem karşısında büyük gelişmeler kaydetmiştir. Derin öğrenme yöntemlerindeki son gelişmeler, görüntü işleme, DDİ, sayısal veri analizi ve tahminleri, ses tanıma gibi son derece farklı alanlarda çeşitli kullanım ve uygulamalara olanak sağlamaktadır. Ancak derin öğrenmede, zaman ve işlem gücü konusunda pahalı eğitim süreçleri ve kapsamlı etiketlenmiş eğitim verilerinin gerekliliği gibi kısıtlamalar çalışmaları zorlaştıran önemli faktörler olarak karşımıza çıkmaktadır (Iman vd., 2020).

Makine öğrenmesinin başlangıcından bu yana transfer öğrenme bu alanda çalışanlar için önemli bir alan olmuştur. Derin öğrenme modellerinin ortaya çıkmasından önce transfer öğrenme, alan uyarlaması olarak biliniyordu ve makine öğrenimi algoritmalarının doğası gereği homojen veri kümelerine ve bu kümelerin birbirleriyle nasıl ilişkilendirileceğine odaklanıyordu (Zhuang vd., 2020; Farahani vd., 2021). Geleneksel Makine Öğrenmesi modelleri, veri kümesi boyutuna daha az bağımlıdır ve çoğunlukla doğrusal problemler için tasarlandıkları için eğitimleri zaman ve işlem gücü bakımından derin öğrenme modellerine göre daha az maliyetlidir. Bu nedenle, derin öğrenmede transfer öğrenmeyi kullanma isteği, kapsamlı eğitim verileri ve eğitim maliyetleri gibi iki temel problemde yardımcı olabileceği için yapay zeka ve makine öğrenmesi alanlarında her zamankinden daha yüksektir (Iman vd., 2023). Şekil 2.9.’da geleneksel makine öğrenmesi ile transfer öğrenme arasındaki fark gösterilmektedir.




Şekil 2.9. Geleneksel makine öğrenmesiyle transfer öğrenme farkı a) Geleneksel makine öğrenmesi b) Transfer öğrenme

Transfer öğrenme, bir modelin bir görev üzerinde eğitilmesini daha sonra öğrenilen bilginin farklı ancak benzer bir göreve uygulanmasını içerir. Buradaki fikir, kaynak görevin eğitimi sırasında kazanılan bilginin hedef görevin öğrenilmesinde faydalı olabileceğidir. Transfer öğrenmenin arkasındaki temel, görevler arasında ortak özellikler ve temsillerin olduğu varsayımında yatmaktadır. Transfer öğrenme, her görev için sıfırdan bir model eğitmek yerine bilgiyi yeniden kullanmamıza olanak tanıyarak ihtiyaç duyulan etiketli veri miktarını potansiyel olarak azaltır ve eğitim sürecini hızlandırır (Zhu vd., 2023).

Transfer öğrenmedeki bilgi aktarımı sayesinde, öğrenme süresi ve veri ihtiyacı azalmasına rağmen daha yüksek doğrulukta tahmin yapması sağlanabilmektedir. Transfer Öğrenme, görüntü sınıflandırma görevlerinde oldukça başarılı olmuştur. ImageNet gibi büyük veri kümeleri üzerinde önceden eğitilmiş modellerin, görüntüyle ilgili çeşitli görevler için etkili özellik çıkarıcılar olduğu gösterilmiştir. Transfer Öğrenmenin başarısı kaynak ve hedef görevler arasındaki benzerliğe bağlıdır. Görevler çok farklıysa aktarım etkili olmayabilir. Ayrıca önceden eğitilmiş bir modelin hedef göreve ince ayar yapılırken aşırı uyumun önlenmesine dikkat edilmelidir. Değişken parametreler optimize edilmezse eksik öğrenme veya ezber durumları oluşabilir. Bununla birlikte hedef görev için mevcut verilerin boyutu ve kalitesi, Transfer Öğrenmenin başarısında önemli bir rol oynar. Verilerin eksik olduğu ve tüm sınıfları düzgün temsil edemediği durumlarda aktarım beklenen faydaları sağlayamayabilir (Vrbančić ve Podgorelec, 2020).

3. MATERYAL VE YÖNTEM

Yapılan çalışmada, Jupyter Notebook üzerinde Python programlama dili kullanılmış olup, tüm uygulamalar Kaggle bulut üzerinde NVIDIA Tesla P100 GPU ile gerçekleştirilmiştir. Birleştirilerek 12 farklı sınıf ve 35550 adet görüntüye ulaşan veri kümesi; ResNet101, Vgg19 ve EfficientNetB3 mimarileri ile ince ayar yapılarak tekrar eğitilmiş ve test edilmiştir. Sınıflardaki veri sayılarındaki dengesizlik göz önüne alınarak tabakalı 5-katlı çapraz doğrulama yöntemi kullanılmıştır. Bu sayede çapraz doğrulama yapılırken; eğitim, doğrulama ve test aşamasında kullanılan verinin alt parçaları için sınıflara ait veri oranı korunmaktadır. Çalışmada kullanılan 3 farklı mimaride çapraz doğrulama için 5 farklı veri örnekleme kullanılmış olup, toplamda 15 farklı model oluşturulmuştur. Tüm modellerde Dönem Sayısı (Epoch) 10 olarak belirlenmiş olup optimizasyon algoritması olarak Adamax ve kayıp fonksiyonu olarak Categorical Crossentropy kullanılmıştır. Ayrıca tüm modeller için başlangıç ağırlıkları için imagenet ağırlıkları kullanılmıştır. Görüntülerin tamamı 3 kanallı görüntüler olup eğitim aşamasından önce 224x224 olarak yeniden boyutlandırılmıştır. Ayrıca tüm modellerde, Öğrenme Oranı (Learning Rate) 0,001 ve Yığın Boyutu (Batch Size) 40 olarak kullanılmıştır. Tüm çalışmaya ait süreç akış şeması Şekil 3.1.'de verilmiştir.



Şekil 3.1. Süreç akış şeması

3.1. Veri Arttırma

Veri artırma, makine öğreniminde, özellikle bilgisayarlı görme görevlerinde, mevcut görüntülere çeşitli dönüşümler uygulayarak eğitim veri kümesinin boyutunu yapay olarak artırmak için kullanılan bir tekniktir. Veri artırmanın amacı, eğitim verilerine çeşitlilik katarak modelin yeni, görünmeyen verilere daha iyi genelleştirilmesine yardımcı olmaktır. Görüntü veri kümeleri bağlamında veri arttırma, orijinal görüntülere rastgele dönüşümler uygulamayı, etiket veya sınıf bilgilerini korurken yeni varyasyonlar oluşturmayı içerir (Shorten ve Khoshgoftaar, 2019).

Yaygın görüntü veri arttırma teknikleri arasında; Döndürme, yatay ve dikey çevirme, yakınlaştırma, yatay ve dikey görüntü kaydırma, zıtlık ile parlaklık ayarlamaları ve gürültü ekleme sayılabilir. Bu dönüşümleri uygulayarak model, eğitim sırasında aynı görüntülerin farklı varyasyonlarını görür ve sınıflandırmayı etkilemeyen küçük değişikliklere karşı daha duyarsız olmasını sağlar. Böylece model gerçekten sınıflandırmayı etkileyen özellikleri öğrenirken, sınıflandırmayı etkilemeyen özellikleri yok saymayı öğrenir. Bu da modelin ezber yapmasını önleyerek daha sonra modelin hiç görmediği verilere karşı daha başarılı olmasını sağlar (Chlap vd., 2021).

Veri artırma, ek etiketli örnekler toplamadan veri kümesinin etkin boyutunu etkili bir şekilde arttırdığından, eğitim veri kümesinin boyutu sınırlı olduğunda özellikle kullanışlıdır. Derin öğrenme uygulamalarında, özellikle ESA’larda görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevler için yaygın olarak kullanılır (Abayomi-Alli vd., 2021).

1100 adet ToBRFV görüntüsü içeren veri kümesine (Fidan vd., 2021); halihazırda veri arttırma uygulanmış 11 sınıfa ait 32480 görüntüden oluşan “Tomato Disease Multiple Sources” veri kümesi (Pandian vd., 2022) ile birleştirmeden önce döndürme, dikey/yatay çevirme ve yakınlaştırma yöntemleri kullanılarak veri arttırma uygulanmıştır. Veri arttırma sonucu ortaya çıkan 3070 görüntü içeren ToBRFV veri kümesi, “Tomato Disease Multiple Sources” veri kümesi ile birleştirilip toplam 12 sınıfa ait 35550 adet görüntü içeren nihai veri kümesi oluşturulmuştur.

3.2. Veri Kümesi

Çalışmada kullanılan veri kümesi, birden fazla veri kümesinin bir araya getirilmesiyle oluşturulmuştur. Kaggle platformundan elde edilen ve ağırlıklı olarak PlantVillage veri kümesindeki domates hastalıklarına ait verilerin bulunduğu “Tomato


Disease Multiple Sources” adlı veri kümesinde hem laboratuvar ortamında çekilmiş görüntüler hem de sahada çekilmiş görüntüler bulunmaktadır.

ToBRFV veri kümesine veri arttırımı yapılırken; yakınlaştırma, dikey/yatay çevirme, döndürme ve yakınlaştırma işlemleri rastgele uygulanmıştır. Birleştirilen veri kümesine ait tabakalı 5-katlı çapraz doğrulamada (stratified 5-fold cross validation) her doğrulama için sınıflara ait eğitim, doğrulama ve test veri dağılımları Çizelge 3.1.’de verilmiştir.

Çizelge 3.1. Her çapraz doğrulama için veri dağılımları

	Eğitim (%70)	Doğrulama (%10)	Test (%20)	Toplam
Bacterial Spot	2489	355	711	3555
Early Blight	2202	314	629	3145
Late Blight	2723	389	778	3890
Leaf Mold	2419	345	691	3455
Septoria Leaf Spot	2562	366	732	3660
Spider Mites	1519	217	434	2170
Target Spot	1568	224	448	2240
ToBRFV	2149	307	614	3070
TYLCV	1726	246	493	2465
ToMV	1950	278	557	2785
Sağlıklı	2692	384	769	3845
Powdery Mildew	889	127	254	1270
Toplam	24888	3552	7110	35550

Çizelge 3.1.’den de görüleceği üzere veri kümesindeki sınıflara ait görüntü sayıları eşit değildir. Çapraz doğrulama yapılırken tabakalı yapılmasının sebebi; eğitim, doğrulama ve test alt gruplarındaki görüntü sayılarının, ana veri kümesindeki görüntü sayılarıyla orantılı olmasını sağlamaktır. Ana veri kümesindeki görüntülerden oluşan rastgele sınıflara ait örnek görüntüler Şekil 3.2.’de verilmiştir.



Şekil 3.2. Veri kümesindeki rastgele sınıflara ait örnek hastalık görüntüleri

3.3. Tabakalı Çapraz Doğrulama


Çapraz doğrulama, bir modelin performansını ve genelleştirilebilirliğini değerlendirmek için makine öğrenmesinde kullanılan istatistiksel bir tekniktir. Temel amacı, veri kümesini alt kümelerle bölmek, modeli bu alt kümelerin bazıları üzerinde eğitmek ve ardından geri kalan veriler üzerindeki performansını değerlendirmektir. Bu süreç, modelin yeni, görülmemiş veriler üzerinde ne kadar iyi performans göstereceğinin tahmin edilmesine yardımcı olur (Ramezan vd., 2019).

En sık kullanılan çapraz doğrulama tekniklerinin başında k-katlı çapraz doğrulama yöntemi gelmektedir. Yöntemi uygulamak için önce tüm veri kümesi, k sabit sabit sayısı kadar alt kümeye bölünür ve her alt küme kabaca aynı sayıda veri örneği içerir. Oluşturulan k sayıdaki katlardan, k-1 sayıdaki katlar eğitim için kullanılırken, son alt

küme üzerinde test edilir. Test kümesi her seferinde değiştirilmek suretiyle bu işlem k sayısı kadar tekrarlanır. Her tekrarlamaya işlemi için doğruluk, kesinlik, duyarlılık, F1 skoru gibi performans metrikleri ayrı ayrı hesaplanır (Tougui vd., 2021).

Çapraz doğrulama sayesinde veri kümesinin tüm alt gruplarına test aşaması uygulanıp, modelin yeteneklerine ilişkin sonuçlar çapraz olarak güvenceye alınmış olur. Ayrıca varyansın azaltılması ile verilerin, eğitim ve test kümelerine bölünme şeklinin etkisini azaltır. Tek bir eğitim-test bölünmesi, her kümede yer alan örneklere bağlı olarak performans tahmininde yüksek farklılıklara neden olabilir. Ek olarak çapraz doğrulama, bir modelin görünmeyen veriler üzerindeki performansına ilişkin daha doğru bir tahmin sağlayarak, modelin eğitim verilerinin ötesinde etkili bir şekilde genelleştirilmesinin sağlanmasına yardımcı olur. Çapraz doğrulamanın bir başka faydası da farklı modellerin birden fazla kattaki performanslarını değerlendirerek karşılaştırılmasına yardımcı olur. Temelde çapraz doğrulama, makine öğrenmesi modellerini değerlendirmek ve geliştirmek için çok önemli bir araçtır ve tek bir eğitim/test ayırımına kıyasla daha sağlam bir değerlendirme sunar (Berrar, 2019).

Tabakalı çapraz doğrulama ise k-katlı çapraz doğrulamanın en yaygın kullanılan varyasyonları arasında yer almaktadır. Tabakalı çapraz doğrulamada, her kattaki alt örneklem kümelerinde hedef sınıf dağılımlarının korunması sağlanır. Bu durum özellikle, sınıf dağılımlarının eşit dağılmadığı dengesiz veri kümeleriyle çalışırken önemlidir. Tabakalı çapraz doğrulamanın amacı, her bir alt örneklem kümesinde orijinal veri kümesiyle benzer sınıf dağılımlarının sürdürülmesinin sağlanmasıdır (Prusty vd., 2022). Tabakalı çapraz doğrulama örneği Şekil 3.3.'te verilmiştir.



Şekil 3.3. Tabakalı çapraz doğrulama örneği (Wu, Zhang ve Li, 2022).


Tabakalı k-katlamının kullanılmasıyla çapraz doğrulama süreci, dengesiz veri kümeleriyle uğraşırken daha güvenilir hale gelir. Geleneksel çapraz doğrulama, yanlışlıkla bazı katlamaların azınlık sınıflarının yeterli temsilinden yoksun olmasına ve bu da taraflı performans tahminlerine yol açabilir. Tabakalı çapraz doğrulama, özellikle belirli sınıfların nadir olduğu senaryolarda modelin performansının daha doğru bir şekilde değerlendirilmesini sağlayarak bu sorunun hafifletilmesine yardımcı olur (Szeghalmy ve Fazekas, 2023).

Özetle, tabakalı k-katlı çapraz doğrulama, model değerlendirme süreci sırasında tüm katlamalarda tutarlı bir sınıf dağılımını koruyarak sınıf dengesizliğiyle ilgili potansiyel sorunları ele almak üzere tasarlanmış standart çapraz doğrulama yaklaşımının geliştirilmiş halidir.

Yapılan çalışmada öğrenme aşamasından önce veri kümesine, tabakalı 5-katlı çapraz doğrulama uygulanması ile, aynı veri kümesinden farklı eğitim, doğrulama ve test örneklemelerinden oluşan 5 farklı alt veri kümeleri (katlar) oluşturulmuştur. Her bir kat, aynı birleşik veri kümesinin, farklı eğitim, doğrulama ve test varyasyonlarını içermektedir. Her bir kat eğitim, doğrulama ve test dağılımı olarak sırasıyla %70, %10 ve %20 veri içermektedir. 5 katın her birinde %20 olmak üzere, veri kümesindeki her bir veri, test aşamasında kullanılmıştır.

3.4. Vgg19

Vgg19, Vgg ailesine ait bir ESA mimarisidir. Sade ve basit yapısıyla ön plana çıkan bu model Oxford Üniversitesi Görsel Geometri Grubu tarafından oluşturulmuştur. 19 adet evrişim ve tam bağlantı katmanı bulunduğu için Vgg19 olarak adlandırılmaktadır. Ardışık evrişim katmanlarından oluşan evrişim blokları temel yapıyı oluştururken her evrişim bloğunun ardından maksimum havuzlama kullanılmaktadır. Evrişim bloklarında aktivasyon fonksiyonu olarak Relu, evrişim filtresi olarak 3x3 filtreler kullanılmaktadır. 5 adet evrişim bloğu ve maksimum havuzlama katmanlarının ardından, sonuncusu sınıflandırma için olmak üzere 3 adet tam bağlantı katmanı ile ağ sonlanmaktadır. Tam bağlantı katmanlarında da aktivasyon için Relu fonksiyonu kullanılmakta olup sınıflandırma için son katmanda sınıf sayısı kadar nöron ile birlikte softmax fonksiyonu kullanılmaktadır. Vgg19'a ait 1000 sınıf için oluşturulmuş temel mimari Şekil 3.4.'te verilmiştir (Bansal vd., 2021).




Şekil 3.4. 1000 sınıf için temel Vgg19 mimarisi

3.5. ResNet101


ESA tabanlı mimarilerin başarılarının artmasıyla birlikte gittikçe daha derin ağlar ön plana çıkmaya başlamıştır. Başlangıçta ağın derinleşmesi hata oranını azaltıp başarıyı arttırsa da ağ derinleştikçe tipik bir derin öğrenme problemi olan, kaybolan/patlayan gradyanlar (vanishing/exploding gradient) problemi ortaya çıkmıştır. Bu problem ağın derinleşmesiyle oluşan bozulma ve optimizasyon probleminden meydana gelmektedir (Hanin, 2018).

ResNet’ler artık bağlantı adı verilen ağ içindeki kısayol bağlantılarıyla katman giriş verisini, birkaç katman öteye taşır. Bu sayede derin ağlarda bilgi, kaybolan gradyan sorunu olmadan daha da derin katmanlara taşınabilmektedir (Tong vd., 2020). Temel artık bloğu Şekil 3.5.’te gösterilmiştir.



Şekil 3.5. Temel artık blok (He vd., 2016)

Şekil 3.5.’te gösterildiği gibi, artık bağlantı olmadan x girdisinin ağırlıklandırılmasıyla elde edilecek fonksiyon $f(x)$ olurken, artık bağlantı ile çıkış değerimiz $f(x) + x$ olmaktadır. Bu sayede ResNet’lerde kaybolan gradyan problemi ortadan kalkmaktadır. Artık bağlantı bloklarının, evrişim katmanlarında belirli bir düzende kullanılmasıyla ResNet mimarileri oluşmuştur. Temel ResNet101 mimarisi Şekil 3.6.’da verilmiştir.




Şekil 3.6. ResNet101 temel mimarisi

3.6. EfficientNetB3

Yeni bir ESA geliştirildiğinde, sabit bir kaynak maliyetiyle gerçekleştirilir. Daha fazla kaynak ulaşılabilir olduğunda daha iyi doğruluk elde etmek için bu ağların ölçeği daha sonra büyütülür. Çoğu durumda, bu ölçeklendirme tekniği, kıyaslama veri kümelerinin büyük kısmında daha iyi doğruluk sağlanmasına yardımcı olmuştur. Ancak model ölçeklendirmenin geleneksel teknikleri oldukça rastgeledir. Bazı modeller derinlik (katman sayısı) yönünde, bazıları ise genişlik (nöron sayısı) yönünde ölçeklendirilir. Bazı modeller daha iyi sonuçlar elde etmek için daha yüksek çözünürlüklü görüntüler kullanır. Modelleri rastgele ölçeklendirmeye yönelik bu teknik, manuel ayarlama ve uzun zaman gerektirir; bu da genellikle performansta çok az iyileşme sağlar veya hiç iyileşme sağlamaz. EfficientNet modelleri ise basit ama etkili bir şekilde ölçeklendirmek için bileşik katsayı adı verilen bir teknik kullanır. Bileşik ölçeklendirme, genişliği, derinliği veya çözünürlüğü rastgele ölçeklendirmek yerine, her boyutu belirli bir sabit ölçeklendirme katsayılarıyla dengeli bir şekilde ölçeklendirir. Bu sayede EfficientNet mimarileri dengeli bir ölçeklendirme ile birçok veri kümesinde başarılı sonuçlar elde etmiştir (Tan ve Le, 2019).

EfficientNet'in temel evrişim bloğu, ilk olarak MobileNet mimarisinde karşımıza çıkan ters çevrilmiş darboğaz (MBCon) bloğudur. Mimaride kullanılan bir diğer değişiklik ise evrişim katmanlarındaki derinlik ve noktasal temelli (depthwise/pointwise) evrişimdir. Derinlik ve noktasal temelli evrişim ile mimari, minimum doğruluk kaybıyla hesaplama maliyetini büyük ölçüde azaltmaktadır. Ayrıca MobileNetV2'de bulunan ters

artık bağlantılar (inverted residual connection/IRC) ve doğrusal dar boğazlar (linear bottlenecks) da EfficientNet mimarisinde kullanılmıştır (Alhichri vd., 2021). Ayrıca EfficientNet mimarilerinde temel ESA mimarilerden farklı olarak Swish aktivasyon fonksiyonu ve global ortalama havuzlama (Global Average Pooling/GAP) kullanılmaktadır. EfficientNetB3'e ait temel mimari, Şekil 3.7.'de verilmiştir.



Şekil 3.7. Temel EfficientNetB3 mimarisi (Alhichri vd., 2021)

3.7. Performans Metrikleri

Makine öğrenmesi alanında, doğru ve güvenilir sınıflandırma modellerinin geliştirilmesi, sayısız gerçek dünya probleminin çözümü için büyük önem arz etmektedir. Bir sınıflandırma modelinin etkinliği, farklı sınıflar arasında doğru tahminler yapabilme yeteneğine bağlıdır. Performans metrikleri, farklı sınıflar arasındaki tahmin doğruluğunu

ölçerek, sınıflandırma modelinin etkinliği hakkında bilgi verir ve karşılaştırma imkanı sunar.

Karışıklık veya karmaşıklık matrisi olarak da bilinen hata matrisi, sınıflandırma problemlerinde en sık kullanılan araçlardan biridir. Hata matrisi; Doğru Pozitif (True Positive/TP), Doğru Negatif (True Negative/TN), Yanlış Pozitif (False Positive/FP) ve Yanlış Negatif (False Negative/FN) değerlerini tek bir matris içinde göstererek modelin sınıflandırma doğruluğu performansının ayrıntılı bir analizini sağlar. Ayrıca hata matrisi bileşenleri (TP, TN, FP, FN) ile yaygın olarak kullanılan performans metriklerinin birçoğuna ulaşılabilir.

Doğruluk, tüm sınıflardaki genel tahmin oranını ölçen en temel performans metriklerinin başında gelir. Ancak bir sınıfın diğerine oranla dengesiz olduğu veri kümelerinde en iyi seçim olmayabilir. Doğruluk, Denklem 3.1.'de gösterildiği gibi doğru tahminlerin tüm tahminlere oranı olarak belirlenmektedir. Minimum değeri olan (0) değerine yaklaştıkça modelin çok fazla hata yaptığını ifade ederken, maksimum (1) değerinde modelin tüm tahminleri doğru yaptığını ifade etmektedir. Modele için genel olarak hesaplanabildiği gibi her bir sınıf için ayrı ayrı sınıflandırma doğruluğu hesaplanabilir (Maxwell vd., 2021).

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

Kesinlik ise Denklem 3.2.'de gösterildiği gibi, model tarafından pozitif olarak tahmin edilen arasındaki TP oranını ölçen bir metriktir. Sınıflandırma doğruluğu gibi (0-1) aralığında değişen kesinlik değeri modelin pozitif örnekleri üzerinde ne kadar başarılı olduğunun bir göstergesidir (Vujović, 2021).

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.2)$$

Bir başka önemli metrik olan duyarlılık, modelin bir sınıfla ilgili olan pozitif tüm örnekleri yakalama oranını ifade eder. Sağlık sektörü gibi pozitif örnekleri kaçırmanın maliyetli olduğu durumlarda sıklıkla kullanılır. Duyarlılık denklemi, Denklem 3.3.'de gösterilmiştir (Vujović, 2021).

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.3)$$

F1-Skoru ise hem yanlış pozitifleri hem de yanlış negatifleri dikkate alan tek bir ölçüm sunarak kesinlik ve duyarlılık arasında bir denge sağlar. Eşit olmayan bir sınıf dağılımının olduğu durumlarda özellikle faydalıdır. Bahsedilen diğer metriklerdeki gibi (0-1) aralığında bulunan F1-Skoru, yüksek değerlerde iyi performansa işaretler. F1-Skorunun hesaplanmasına ilişkin hesaplama, Denklem 3.4.'de verilmiştir (Grandini vd., 2020).

$$F1 - Skoru = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.4)$$

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Uygulama aşamasında her bir mimari, tüm veri örneklem gruplarıyla eğitilip test edilmiştir. Oluşturulan tüm modellerde, 10 dönem sonunda elde edilen eğitim, doğrulama ve test aşamalarına ait doğruluk ve kayıp değerleri Çizelge 4.1.'de verilmiştir.

Çizelge 4.1. Eğitim doğrulama ve test aşamalarına ait doğruluk ve kayıp değerleri



		Eğitim		Doğrulama		Test	
		Doğruluk	Kayıp	Doğruluk	Kayıp	Doğruluk	Kayıp
Vgg19	Model 1	0,8936	0,4864	0,8956	0,5461	0,8931	0,5385
	Model 2	0,8685	0,6368	0,8368	0,7160	0,8489	0,7369
	Model 3	0,9005	0,5234	0,8891	0,5413	0,8700	0,5786
	Model 4	0,8390	0,7442	0,7977	0,7971	0,8060	0,8096
	Model 5	0,8589	0,6428	0,8323	0,7503	0,8330	0,7249
	Ortalama	0,8721	0,6067	0,8503	0,6702	0,8502	0,6777
ResNet101	Model 1	0,9995	0,1341	0,9856	0,1900	0,9811	0,1955
	Model 2	0,9990	0,1439	0,9691	0,2421	0,9787	0,2083
	Model 3	0,9963	0,1661	0,9723	0,2550	0,9468	0,3009
	Model 4	0,9995	0,1490	0,9793	0,2156	0,9521	0,2772
	Model 5	0,9995	0,1438	0,9739	0,2374	0,9894	0,2136
	Ortalama	0,9988	0,1474	0,9760	0,2280	0,9696	0,2391
EfficientNetB3	Model 1	1	0,1143	0,9914	0,1536	0,9954	0,1330
	Model 2	0,9989	0,1184	0,9925	0,1458	0,9947	0,1165
	Model 3	0,9995	0,1193	0,9941	0,1386	0,9947	0,1265
	Model 4	0,9984	0,1291	0,9883	0,1653	0,9895	0,1615
	Model 5	0,9995	0,1220	0,9878	0,1645	0,9894	0,1708
	Ortalama	0,9993	0,1206	0,9908	0,1536	0,9927	0,1417

Çizelge 4.1.'de yer alan test doğruluğu sonuçlarına göre en başarılı model %99,54 ile EfficientNetB3-Model 1 olmuştur. Aynı model ayrıca %100 eğitim doğruluğu göstermiştir. Çalışmadaki diğer modellerden Vgg19-Model 4, %80,60 test doğruluğu performansı ile Vgg19 mimarisinin en düşük doğruluğa sahip modeli olurken, Vgg19-Model 1 %89,31 test doğruluğu ile aynı mimarideki en yüksek performansı göstermiştir.


Resnet101 mimarisinde ise en düşük test doğruluğu %94,68 ile ResNet101-Model 3 olurken, %98,94 test doğruluğu ile Model 5 en iyi ResNet101 modeli olmuştur. EfficientNetB3 mimarisi ile elde edilen sonuçlarda ise Model 5, %98,94 test doğruluğu ile kendi mimarisinde en düşük performansı gösterirken, %99,54 test doğruluğu ile EfficientNetB3-Model 1, hem EfficientNetB3 mimarisinin hem de tüm çalışmanın en yüksek test doğruluğu performansını vermiştir. Ortalama test doğruluklarına bakıldığında, Vgg19, ResNet101 ve EfficientNetB3 mimarilerine ait ortalama test doğrulukları sırasıyla %85,02, %96,96 ve %99,27 olmuştur. Genel olarak sonuçlara bakıldığında doğruluk başarısında en başarılı mimari EfficientNetB3 olurken, üç mimari arasında en başarısız Vgg19 mimarisi olmuştur.

Test aşamasındaki ortalama kayıp değerleri incelendiğinde Vgg19 mimarisi 0,6777 kayıp değeri ile 3. sırada yer alırken, ResNet101 mimarisi 0,2391 ortalama kayıp değeri ile 2. olmuştur. En düşük ortalama kayıp değerini ise 0,1417 ile EfficientNetB3 mimarisi sağlamıştır.


Tüm modeller arasında EfficientNetB3-Model 1, %100 eğitim, %99,14 doğrulama ve %99,54 test doğruluğu ile en başarılı model olmuştur. Üç farklı mimariden, her mimariye ait test doğruluğu değeri en yüksek modeller ise Vgg19-Model 1, ResNet101-Model 5 ve EfficientNetB3-Model 1 olmuştur. Bu modellere ait eğitim ve doğrulama boyunca döneme bağlı kayıp ve doğruluk grafikleri sırasıyla Şekil 4.1. Şekil 4.2. ve Şekil 4.3.'te verilmiştir.



Şekil 4.1. Vgg19-Model 1'e ait döneme bağlı kayıp ve doğruluk; a) Kayıp b) Doğruluk





a)



b)


Şekil 4.2. ResNet101-Model 5'e ait döneme bağlı kayıp ve doğruluk; a) Kayıp b) Doğruluk




Şekil 4.3. EfficientNetB3-Model 1'e ait döneme bağlı kayıp ve doğruluk; a) Kayıp b) Doğruluk

Şekil 4.1.'deki grafiğe göre Vgg19-Model 1 doğruluk ve kayıp bakımından bazı dönemlerde performans düşüşü yaşarken Şekil 4.2.'de gösterilen ResNet101-Model 5, eğitim ve doğrulama boyunca kayıp bakımından daha az değişkenlik göstermiştir. Ancak ResNet101-Model 5, doğruluk bakımından bazı dönemlerde düşüşler yaşamıştır. Ancak çalışma kapsamında tüm modeller arasından test doğruluğu bakımından en başarılı model olan Şekil 4.3.'teki EfficientNetB3-Model 1, eğitim boyunca hem doğruluk hem de kayıp olarak daha istikrarlı bir sonuç vermiştir. EfficientNet-Model 1'e ait doğruluk değeri dışında, Vgg19-Model 1, ResNet101-Model 5 ve EfficientNet-Model 1 modellerinin üçünde de doğruluk ve kayıp değerleri için en iyi dönem, 10. doğrulama dönemi olmuştur. EfficientNet-Model 1'e ait doğruluk değerinde ise en iyi dönem 9. doğrulama dönemi olup, 10. doğrulama döneminde, doğruluk az da olsa düşmüştür.


Vgg19-Model 1, ResNet101-Model 5 ve EfficientNetB3-Model 1 için test aşamasındaki sınıflara ait tahminlerin bulunduğu hata matrisi sırasıyla Şekil 4.4., Şekil 4.5. ve Şekil 4.6.'da verilmiştir.



Şekil 4.4. Vgg19-Model 1'e ait hata matrisi



Şekil 4.5. ResNet101-Model 5'e ait hata matrisi



Şekil 4.6. EfficientNetB3-Model 1'e ait hata matrisi

Hata matrislerine bakıldığında, EfficientNetB3-Model 1'in diğer modellere nazaran çok daha iyi sınıflandırma yaptığı görülmektedir. Ayrıca aynı model ToBRFV sınıfına ait görsellerin tamamını doğru tahmin etmiştir. Sadece 2 adet sağlıklı ve 1 adet ToMV görsellerini ToBRFV olarak yanlış sınıflandırmıştır. Ayrıca Bacterial Spot sınıfında diğer sınıflara oranla fazla hata yaptığı söylenebilir. Model, 13 adet Bacterial Spot sınıfına ait görseli, Septoria Leaf Spot olarak sınıflandırmıştır. EfficientNetB3-Model 1; Spider Mites, ToBRFV ve Powdery Mildew sınıflarına ait görsellerin tamamını doğru tahmin etmiştir.

Vgg19-Model 1 ile ResNet101-Model 5 ise ToBRFV sınıfından, sırasıyla 6 ve 1 görseli yanlış sınıflandırmışlardır. ResNet101-Model 5, ağırlıklı olarak Bacterial Spot, Early Blight ve Septoria Leaf Spot sınıflarında hata yaparken, Vgg19-Model 1 ToBRFV, TYLCV ve ToMV hastalıklarına ait sınıflarda diğer sınıflara oranla daha az hata yaptığı söylenebilir. Ancak Bacterial Spot, Early Blight, Late Blight, Septoria Leaf Spot ve Powdery Mildew sınıflarında yüksek oranda hatalı sınıflandırma yapmıştır.

Ek olarak tüm modeller Bacterial Spot ve Early Blight sınıflarını, diğer hatalı sınıflandırmalardan daha belirgin bir şekilde Septoria Leaf Spot olarak sınıflandırmışlardır.

Vgg19-Model 1, ResNet101-Model 5 ve EfficientNetB3-Model 1'deki sınıflara ait kesinlik, duyarlılık ve F1 skoru değerleri sırasıyla Çizelge 4.2., 4.3. ve 4.4.'te verilmiştir.

Çizelge 4.2. Vgg19-Model 1'deki sınıflara ait performans değerleri

	Kesinlik	Duyarlılık	F1 Skoru
Bacterial_spot	0,90	0,82	0,86
Early_blight	0,91	0,84	0,87
Late_blight	0,89	0,80	0,84
Leaf_Mold	0,81	0,90	0,85
S_leaf_spot	0,78	0,86	0,82
Spider_mites	0,97	0,95	0,96
Target_Spot	0,98	0,86	0,91
ToBRFV	0,88	0,99	0,93
TYLCV	0,91	0,98	0,94
ToMV	0,94	0,98	0,96
Sağlıklı	0,97	0,97	0,97
Powdery_Mildew	0,72	0,67	0,69

Çizelge 4.3. ResNet101-Model 5'teki sınıflara ait performans değerleri

	Kesinlik	Duyarlılık	F1 Skoru
Bacterial_spot	0,98	0,97	0,98
Early_blight	0,97	0,96	0,96
Late_blight	0,98	0,98	0,98
Leaf_Mold	0,99	0,99	0,99
S_leaf_spot	0,95	0,96	0,95
Spider_mites	1,00	0,99	0,99
Target_Spot	0,96	0,99	0,98
ToBRFV	1,00	1,00	1,00
TYLCV	1,00	0,99	0,99
ToMV	0,99	1,00	0,99
Sağlıklı	0,99	0,99	0,99
Powdery_Mildew	0,98	0,98	0,98

Çizelge 4.4. EfficientNetB3-Model 1'teki sınıflara ait performans değerleri

	Kesinlik	Duyarlılık	F1 Skoru
Bacterial_spot	0,99	0,97	0,98
Early_blight	0,99	0,99	0,99
Late_blight	0,99	0,99	0,99
Leaf_Mold	0,99	0,99	0,99
S_leaf_spot	0,98	0,98	0,98
Spider_mites	1,00	1,00	1,00
Target_Spot	1,00	1,00	1,00
ToBRFV	1,00	1,00	1,00
TYLCV	1,00	1,00	1,00
ToMV	1,00	1,00	1,00
Sağlıklı	0,99	0,99	0,99
Powdery_Mildew	0,98	1,00	0,99

Çizelgelerdeki değerler göz önüne alındığında performans metrikleri bazında Vgg19-Model 1 bazı sınıflarda yüksek performans gösterirken bazı hastalık sınıflarında düşük performans göstermiştir. ResNet101-Model 5 ise hastalık sınıflarının çoğunda ortalamanın üzerinde performans göstermiştir. Ancak tüm mimariler ve modeller dikkate alındığında EfficientNetB3-Model 1, hastalık sınıflarının neredeyse tamamında mükemmel yakın performans gösterdiği söylenebilir.

Çalışmada test doğruluğu olarak en başarılı model olan EfficientNetB3-Model 1 ile literatürde incelenen diğer domates hastalığı sınıflandırma modellerinin karşılaştırması Çizelge 4.5.'te verilmiştir.

Çizelge 4.5. Çalışmada oluşturulan modelin diğer modellerle karşılaştırması

Yazar ve Yıl	Veri Kümesi			Veri Arttırma	Transfer Öğrenme	Mimari/ Algoritma	Performans	Diğer Teknikler
	Sınıflar	Görüntü	Eğitim/Test/ Doğrulama					
Brahimi vd., 2017	10	14828	-	Hayır	Evet	GoogleNet	Doğruluk %99,18	SVM, RF, AlexNet
Rangarajan vd., 2018	7	13262	-	Hayır	Evet	AlexNet	Doğruluk %97,49	Vgg 16
De Luna vd., 2018	4	4923	80/20/0	Evet	Evet	FRCNN	Doğruluk 95,75	-
Wang vd., 2019	11	286	60/20/20	Hayır	Hayır	FRCNN, Mask RCNN	En yüksek doğruluk ResNet 101 ile	ResNet 50, ResNet 101, MobileNet, Vgg 16
Agarwal vd., 2020	10	1800	77/6/17	Evet	Hayır	Kendi oluşturduğu ESA	Doğruluk 98,7	-
Maeda-Gutiérrez vd., 2020	10	16419	80/20/0	Hayır	Evet	GoogleNet	Duyarlılık %99	AlexNet, Inception V3, ResNet 18, ResNet 50
Verma vd., 2020	3	2342	80/20/0	Hayır	Evet	AlexNet	Transfer için doğruluk %89,69 ve özellik çıkarma ile %93,4	Squeeze Net, Inception V3
Karthik vd., 2020	4	120000	-	Evet	Hayır	Kendi oluşturduğu ESA	Doğruluk %98	-
Da Costa vd., 2020	2	43843	50/25/25	Hayır	Evet	ResNet50	Kesinlik %94,6	ResNet 101, ResNet34
Bu çalışma	12	35550	70/20/10	Evet	Evet	Efficient NetB3	Doğruluk %99,54	Vgg 19, ResNet 101

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, domates bitki yaprağına ait veri arttırımı uygulanmış ve birleştirilmiş, ToBRFV hastalığı da dahil olmak üzere toplam 35550 görüntüden oluşan özgün bir veri kümesi kullanılmıştır. Oluşturulan veri kümesinde bulunan, 12 farklı hastalıklı ve sağlıklı etiketine sahip sınıflar, farklı ESA mimarileri kullanılarak sınıflandırılmıştır. Veri kümesi, tabakalı 5-katlı çapraz doğrulama ile örneklenmiş, ana veri kümesindeki sınıflara ait dağılım ile birlikte eğitim, doğrulama ve test aşamaları için elde edilen alt gruplarda oluşan sınıflara ait dağılımların korunması ve tüm görsellerin test aşamasında değerlendirilmesi sağlanmıştır. Çalışmalarda, görüntü sınıflandırmada diğer veri kümelerinde ve görevlerde yaygın olarak kullanılan Vgg19, ResNet101 ve EfficientNetB3 ESA mimarileri transfer öğrenme yardımıyla kullanılmıştır. Her bir mimari için tabakalı 5-katlı çapraz doğrulamayla, test grubu farklı 5 ayrı veri örneklem grubu oluşturulmuştur. Diğer parametreler aynı kalmak suretiyle eğitim, doğrulama ve test oranları sırasıyla %70-%10-%20 olacak şekilde her mimaride 5 farklı örneklem grubuyla eğitim, doğrulama ve test yapılmıştır. 10 dönemlik eğitim sürecinin ardından toplam 15 modele ait eğitim, doğrulama ve test aşamalarındaki doğruluk ve kayıp değerleri belirlenmiştir. Bunlara ek olarak her mimari grubundaki test doğruluğu en yüksek modele ait; hata matrisi, kesinlik, duyarlılık ve F1 skoru değerleri belirlenip incelenmiştir.

Test doğruluğu olarak, 10 dönemlik eğitim sonunda 7110 test görüntüsü üzerinde yapılan çalışmalarda en başarılı model %99,54 ile EfficientNetB3-Model 1 olmuştur. Ayrıca bahsi geçen model %100 eğitim doğruluğuna ulaşmıştır. Çalışmada elde edilen sonuçlara göre Vgg19 mimarisinden oluşan modeller ortalama %85,02 test doğruluğu gösterirken Resnet101 mimarisi %96,96, EfficientNetB3 mimarisi ise %99,27 ortalama test doğruluğu performansı göstermiştir. Sınıf etiketleri için ayrıntılı sonuçlarda ise EfficientNetB3-Model 1, 12 sınıf arasından ToBRFV sınıfı dahil 3 sınıfa ait görüntüleri tamamen doğru tahmin etmiştir. ResNet101-Model 5 ise sadece ToBRFV sınıfına ait görüntüleri tamamen doğru tahmin etmiştir. Vgg19-Model-1 ToBRFV sınıfına ait görüntülerde iyi bir sonuç sergilemesine rağmen diğer sınıfların büyük çoğunluğunda geride kalmıştır.

Vgg19 modellerinin sınıfların genelinde yetersiz kaldığı ancak ResNet101 modellerinin genel olarak ortalamanın üzerinde, EfficientNetB3 modellerinin ise mükemmele yakın sınıflandırma yaptığı söylenebilir. Genel olarak tüm modellerin

ToBRFV hastalığını yüksek oranda yakaladığı söylenebilir. Ağdaki değişkenlerin optimizasyonu ile özellikle Vgg19 ve ResNet101 modellerinin performanslarının bir miktar iyileştirilebileceği düşünülmektedir.

ToBRFV hastalığının sınıflandırılması için EfficientNetB3 başta olmak üzere transfer öğrenme mimarileri rahatlıkla kullanılabilir. Ayrıca transfer öğrenme mimarilerinin herhangi bir ön işleme ve özellik çıkarmaya ihtiyaç duymadan, sadece veri arttırımı ve 10 dönemlik eğitim ile mükemmel yakın performans göstermesi önemli bir çıktıdır. Ayrıca veri kümesinin sınıflara ait görüntü dağılımlarının dengeli olmadığı durumlarda bile özellikle ResNet101 ve EfficientNetB3 mimarilerinde, eksik öğrenme meydana gelmemiştir.

Yapılan bu çalışmada yeni sınıfların eklenmesine rağmen yüksek başarı elde edildiği görülmüştür. Çalışmada kullanılan veri kümesine, domateste ortaya çıkan diğer hastalıklar da dahil edilerek veri kümesi genişletilebilir. Tüm domates hastalıklarını kapsayacak bir model oluşturulabilir. Veri kümesi diğer bitki ve hastalıkları da içerecek şekilde kapsamı genişletilebilir. Diğer yaygın ESA mimarileri kullanılarak çalışmanın kapsamı genişletilebilir. Ayrıca hiperparametre optimizasyonu ile, en başarılı modeller için optimum sonuç elde edilebilir. Ek olarak, farklı ESA mimarilerinin birlikte kullanılması ile oluşan topluluk öğrenmesi modelleri oluşturulabilir.

Yeni teknolojilerin ve yapay zekanın tarıma entegre edilmesi ile tarımın dijitalleşmesi, ülkemizdeki tarımsal alanların daha verimli kullanılmasına yardımcı olacaktır. Bu sayede ekonomik kalkınmanın arttırılmasının yanı sıra tarımdaki iş gücü yoğunluğu azaltılarak diğer sektörlerle de katkı yapacağı söylenebilir. Yapılan çalışmanın bu bağlamda, tarımsal üretimdeki kayıpları azaltarak ülkemizdeki tarımın gelişmesine katkı sağlayacağı düşünülmektedir.

KAYNAKLAR

- Abayomi-Alli, O. O., Damaševičius, R., Misra, S., ve Maskeliūnas, R. (2021). Cassava disease recognition from low-quality images using enhanced data augmentation model and deep learning. *Expert Systems*, 38(7), e12746.
- Aceto, G., Persico, V., ve Pescapé, A. (2019). A survey on information and communication technologies for industry 4.0: State-of-the-art, taxonomies, perspectives, and challenges. *IEEE Communications Surveys & Tutorials*, 21(4), 3467-3501.
- Agarwal, M., Gupta, S. K., ve Biswas, K. K. (2020). Development of efficient CNN model for tomato crop disease identification. *Sustainable Computing: Informatics and Systems*, 28, 100407.
- Albawi, S., Mohammed, T. A., ve Al-Zawi, S. (2017). Understanding of a convolutional neural network. In *2017 International Conference on Engineering and Technology (ICET)* (pp. 1-6). IEEE, Antalya, Türkiye.
- Alhichri, H., Alswayed, A. S., Bazi, Y., Ammour, N., ve Alajlan, N. A. (2021). Classification of remote sensing images using EfficientNet-B3 CNN model with attention. *IEEE Access*, 9, 14078-14094.
- Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A., ve Aljaaf, A. J. (2020). A systematic review on supervised and unsupervised machine learning algorithms for data science. *Supervised and Unsupervised Learning for Data Science*, 3-21.
- Alpaydin, E. (2021). *Machine Learning*. Cambridge, MA, USA: MIT Press.
- An, H., Kwon, S., ve Park, M. (2019). A case study on the recommendation services for customized fashion styles based on artificial intelligence. *Journal of the Korean Society of Clothing and Textiles*, 43(3), 349-360.
- Araújo, S. O., Peres, R. S., Barata, J., Lidon, F., ve Ramalho, J. C. (2021). Characterising the agriculture 4.0 landscape emerging trends, challenges and opportunities. *Agronomy*, 11(4), 667.
- Awokuse, T. O., ve Xie, R. (2015). Does agriculture really matter for economic growth in developing countries?. *Canadian Journal of Agricultural Economics/Revue canadienne d'agroeconomie*, 63(1), 77-99.
- Badiane, O. (2008). *Sustaining and accelerating Africa's agricultural growth recovery in the context of changing global food prices* (No. 599-2016-40125).
- Bansal, M., Kumar, M., Sachdeva, M., ve Mittal, A. (2021). Transfer learning for image classification using VGG19: Caltech-101 image data set. *Journal of Ambient Intelligence and Humanized Computing*, 1-12.

- Bao, Y., Hilary, G., ve Ke, B. (2022). Artificial intelligence and fraud detection. *Innovative Technology at the Interface of Finance and Operations*, 223-247.
- Basha, S. S., Dubey, S. R., Pulabaigari, V., ve Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119.
- Belk, R. (2021). Ethical issues in service robotics and artificial intelligence. *The Service Industries Journal*, 41(13-14), 860-876.
- Berrar, D. (2019). Cross-Validation. *Encyclopedia of Bioinformatics and Computational Biology*, 1, 542-545.
- Bertolini, M., Mezzogori, D., Neroni, M., ve Zammori, F. (2021). Machine Learning for industrial applications: A comprehensive literature review. *Expert Systems with Applications*, 175, 114820.
- Brahimi, M., Boukhalfa, K., ve Moussaoui, A. (2017). Deep learning for tomato diseases: classification and symptoms visualization. *Applied Artificial Intelligence*, 31(4), 299-315.
- Brill, T. M., Munoz, L., ve Miller, R. J. (2018). Siri, Alexa, and Other Digital Assistants: A Study of Customer Satisfaction with Artificial Intelligence Applications. In *2018 AMA Summer Academic Conference* (p. 44), Boston, MA, USA.
- Burkart, N., ve Huber, M. F. (2021). A survey on the explainability of supervised machine learning. *Journal of Artificial Intelligence Research*, 70, 245-317.
- Chlap, P., Min, H., Vandenberg, N., Dowling, J., Holloway, L., ve Haworth, A. (2021). A review of medical image data augmentation techniques for deep learning applications. *Journal of Medical Imaging and Radiation Oncology*, 65(5), 545-563.
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., ve Campbell, J. P. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science & Technology*, 9(2), 14-14.
- Chowdhary, K., ve Chowdhary, K. R. (2020). Natural language processing. *Fundamentals of Artificial Intelligence*, 603-649.
- Da Costa, A. Z., Figueroa, H. E., ve Fracarolli, J. A. (2020). Computer vision based detection of external defects on tomatoes using deep learning. *Biosystems Engineering*, 190, 131-144.
- De Luna, R. G., Dadios, E. P., ve Bandala, A. A. (2018). Automated image capturing system for deep learning-based tomato plant leaf disease detection and recognition. In *TENCON 2018-2018 IEEE Region 10 Conference* (pp. 1414-1419). IEEE.
- Dong, S., Wang, P., ve Abbas, K. (2021). A survey on deep learning and its applications. *Computer Science Review*, 40, 100379.

- El Naqa, I., ve Murphy, M. J. (2015). *What is Machine Learning?* (pp. 3-11). Springer International Publishing.
- Eisenstein, J. (2019). *Introduction to Natural Language Processing*. Cambridge, MA, USA: MIT press.
- Farahani, A., Voghoei, S., Rasheed, K., ve Arabnia, H. R. (2021). A brief review of domain adaptation. *Advances in Data Science and Information Engineering: Proceedings from ICDATA 2020 and IKE 2020*, 877-894.
- Fidan, H., Sarikaya, P., ve Calis, O. (2019). First report of Tomato brown rugose fruit virus on tomato in Turkey. *New Disease Reports* 39(18), 2044-0588.
- Fidan, H., Sarikaya, P., Yildiz, K., Topkaya, B., Erkis, G., ve Calis, O. (2021). Robust molecular detection of the new Tomato brown rugose fruit virus in infected tomato and pepper plants from Turkey. *Journal of Integrative Agriculture*, 20(8), 2170-2179.
- Ghosh, A. M., ve Grolinger, K. (2020). Edge-cloud computing for Internet of Things data analytics: Embedding intelligence in the edge with deep learning. *IEEE Transactions on Industrial Informatics*, 17(3), 2191-2200.
- Goodfellow, I., Bengio, Y., ve Courville, A. (2016). Convolutional networks. In *Deep Learning* (Vol. 2016, pp. 330-372). Cambridge, MA, USA: MIT press.
- Goralski, M. A., ve Tan, T. K. (2020). Artificial intelligence and sustainable development. *The International Journal of Management Education*, 18(1), 100330.
- Grandini, M., Bagli, E., ve Visani, G. (2020). Metrics for multi-class classification: an overview. *arXiv preprint arXiv:2008.05756*.
- Gupta, R., Srivastava, D., Sahu, M., Tiwari, S., Ambasta, R. K., ve Kumar, P. (2021). Artificial intelligence to deep learning: machine intelligence approach for drug discovery. *Molecular Diversity*, 25, 1315-1360.
- Güzel B., ve Okatan E, (2022). Tarım ve Yapay Zekâ. M. Bilen (Ed.), *Yapay Zekânın Değiştirdiği Dinamikler 1* kitabı içinde (s. 199-224). Konya: Eğitim Yayınevi.
- Hanin, B. (2018). Which neural net architectures give rise to exploding and vanishing gradients?. *Advances in Neural Information Processing Systems*, (582-591), Montreal, Canada.
- Harshvardhan, G. M., Gourisaria, M. K., Pandey, M., ve Rautaray, S. S. (2020). A comprehensive survey and analysis of generative models in machine learning. *Computer Science Review*, 38, 100285.
- He, K., Zhang, X., Ren, S., ve Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770-778). Las Vegas, NV, USA.

- Helbing, D. (2019). Societal, economic, ethical and legal challenges of the digital revolution: from big data to deep learning, artificial intelligence, and manipulative technologies. Helbing, D. (Ed.), *Towards Digital Enlightenment*. Kitabı içinde (s. 47-72). Cham, Switzerland: Springer International Publishing.
- Iman, M., Arabnia, H. R., ve Branchinst, R. M. (2020). Pathways to artificial general intelligence: a brief overview of developments and ethical issues via artificial intelligence, machine learning, deep learning, and data science. *International Conference on Artificial Intelligence*, (73-87). Las Vegas, Nevada, USA.
- Iman, M., Arabnia, H. R., ve Rasheed, K. (2023). A review of deep transfer learning and recent advancements. *Technologies*, 11(2), 40.
- Ioffe, S., ve Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International Conference on Machine Learning* (pp. 448-456). Lille, France.
- Jan, Z., Ahamed, F., Mayer, W., Patel, N., Grossmann, G., Stumptner, M., ve Kuusk, A. (2023). Artificial intelligence for industry 4.0: Systematic review of applications, challenges, and opportunities. *Expert Systems with Applications*, 216, 119456.
- Jiang, D., Li, F., Yang, Y., ve Yu, S. (2020). A tomato leaf diseases classification method based on deep learning. In *2020 Chinese Control and Decision Conference (CCDC)* (pp. 1446-1450). Hefei, China: IEEE.
- Jiang, Y., Li, X., Luo, H., Yin, S., ve Kaynak, O. (2022). Quo vadis artificial intelligence?. *Discover Artificial Intelligence*, 2(1), 4.
- Johri, P., Verma, J. K., ve Paul, S. (Eds.). (2020). *Applications of Machine Learning*. Singapore: Springer Nature.
- Jones, J. B., Zitter, T. A., Momol, T. M., ve Miller, S. A. (Eds.). (2014). PART I: Infectious Diseases. In *Compendium of Tomato Diseases and Pests*, Second Edition (pp. 15-119). Minnesota, ABD: The American Phytopathological Society.
- Kamath, U., Liu, J., ve Whitaker, J. (2019). *Deep learning for NLP and Speech Recognition* (Vol. 84). Cham, Switzerland: Springer.
- Karthik, R., Hariharan, M., Anand, S., Mathikshara, P., Johnson, A., ve Menaka, R. (2020). Attention embedded residual CNN for disease detection in tomato leaves. *Applied Soft Computing*, 86, 105933.
- Kelleher, J. D. (2019). *Deep Learning*. Cambridge, MA, USA: MIT press.
- Ketkar, N., Moolayil, J., Ketkar, N., ve Moolayil, J. (2021). Convolutional neural networks. In *Deep Learning with Python: Learn Best Practices of Deep Learning Models with PyTorch*, (197-242). Berkeley, CA, USA: Apress.

- Khan, M. Z., Harous, S., Hassan, S. U., Khan, M. U. G., Iqbal, R., ve Mumtaz, S. (2019). Deep unified model for face recognition based on convolution neural network and edge computing. *IEEE Access*, 7, 72622-72633.
- Kiran, B. R., Sobh, I., Talpaert, V., Mannion, P., Al Sallab, A. A., Yogamani, S., ve Pérez, P. (2021). Deep reinforcement learning for autonomous driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(6), 4909-4926.
- Krichen, M. (2023). Convolutional neural networks: A survey. *Computers*, 12(8), 151.
- Li, Y., Wang, H., Dang, L. M., Sadeghi-Niaraki, A., ve Moon, H. (2020). Crop pest recognition in natural scenes using convolutional neural networks. *Computers and Electronics in Agriculture*, 169, 105174.
- Li, Z., Liu, F., Yang, W., Peng, S., ve Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems* 33(12), 6999-7019.
- Maeda-Gutiérrez, V., Galván-Tejada, C. E., Zanella-Calzada, L. A., Celaya-Padilla, J. M., Galván-Tejada, J. I., Gamboa-Rosales, H., ... ve Olvera-Olvera, C. A. (2020). Comparison of convolutional neural network architectures for classification of tomato plant diseases. *Applied Sciences*, 10(4), 1245.
- Matthews, G., Hancock, P. A., Lin, J., Panganiban, A. R., Reinerman-Jones, L. E., Szalma, J. L., ve Wohleber, R. W. (2021). Evolution and revolution: Personality research for the coming world of robots, artificial intelligence, and autonomous systems. *Personality and Individual Differences*, 169, 109969.
- Maxwell, A. E., Warner, T. A., ve Guillén, L. A. (2021). Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review. *Remote Sensing*, 13(13), 2450.
- Mulugeta, T., Abreha, K., Tekie, H., Mulatu, B., Yesuf, M., Andreasson, E., ... ve Alexandersson, E. (2019). Phosphite protects against potato and tomato late blight in tropical climates and has varying toxicity depending on the *Phytophthora infestans* isolate. *Crop Protection*, 121, 139-146.
- Müller, V. C. (2021). Ethics of artificial intelligence. *The Routledge Social Science Handbook of AI*, (pp. 122-137). London: Routledge.
- Nath, R., ve Sahu, V. (2020). The problem of machine ethics in artificial intelligence. *AI & Society*, 35, 103-111.
- Osman, M. A., Al Dhafar, Z. M., ve Alqahtani, A. M. (2019). Biological responses of the two-spotted spider mite, *Tetranychus urticae* to different host plant. *Archives of Phytopathology and Plant Protection*, 52(17-18), 1229-1238.
- Paleyes, A., Urma, R. G., ve Lawrence, N. D. (2022). Challenges in deploying machine learning: a survey of case studies. *ACM Computing Surveys*, 55(6), 1-29.

- Pandian, A., Geetharamani G., Mei-Ling, H., ve Ya-Han C. (2022). *Tomato Disease Multiple Sources* [Data set]. Kaggle. <https://doi.org/10.34740/KAGGLE/DSV/4270691>
- Prusty, S., Patnaik, S., ve Dash, S. K. (2022). SKCV: Stratified K-fold cross-validation on ML classifiers for predicting cervical cancer. *Frontiers in Nanotechnology*, 4, 972421.
- Rai, R., Tiwari, M. K., Ivanov, D., ve Dolgui, A. (2021). Machine learning in manufacturing and industry 4.0 applications. *International Journal of Production Research*, 59(16), 4773-4778.
- Ramezan, C. A., Warner, T. A., ve Maxwell, A. E. (2019). Evaluation of sampling and cross-validation tuning strategies for regional-scale machine learning classification. *Remote Sensing*, 11(2), 185.
- Rangarajan, A. K., Purushothaman, R., ve Ramesh, A. (2018). Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Computer Science*, 133, 1040-1047.
- Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35.
- Sade, D., Sade, N., Brotman, Y., ve Czosnek, H. (2020). Tomato yellow leaf curl virus (TYLCV)-resistant tomatoes share molecular mechanisms sustaining resistance with their wild progenitor *Solanum habrochaites* but not with TYLCV-susceptible tomatoes. *Plant Science*, 295, 110439.
- Sahu, P. K., Singh, S., Gupta, A., Singh, U. B., Brahmaprakash, G. P., ve Saxena, A. K. (2019). Antagonistic potential of bacterial endophytes and induction of systemic resistance against collar rot pathogen *Sclerotium rolfsii* in tomato. *Biological Control*, 137, 104014.
- Saranya, S. M., Rajalaxmi, R. R., Prabavathi, R., Suganya, T., Mohanapriya, S., ve Tamilselvi, T. (2021). Deep learning techniques in tomato plant—a review. In *Journal of Physics: Conference Series* (Vol. 1767, No. 1, p. 012010). Pollachi, India: IOP Publishing.
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2(3), 160.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.
- Shinde, P. P., ve Shah, S. (2018). A review of machine learning and deep learning applications. In 2018 *Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)* (pp. 1-6). Pune, India: IEEE.
- Shorten, C., ve Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1-48.

- Singh, H., Tewari, U., ve Ushasukhanya, S. (2023). Tomato Crop Disease Classification using Convolution Neural Network and Transfer Learning. In *2023 International Conference on Networking and Communications (ICNWC)* (pp. 1-6). Chennai, India: IEEE.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., ve Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.
- Summers, C. F., Park, S., Dunn, A. R., Rong, X., Everts, K. L., Kleinhenz, M. D., ... ve Smart, C. D. (2014). Fungal and oomycete pathogen detection in the rhizosphere of organic tomatoes grown in cover crop-treated soils. *Applied Soil Ecology*, 80, 44-50.
- Sundararaman, B., Jagdev, S., ve Khatri, N. (2023). Transformative Role of Artificial Intelligence in Advancing Sustainable Tomato (*Solanum lycopersicum*) Disease Management for Global Food Security: A Comprehensive Review. *Sustainability*, 15(15), 11681.
- Syrquin, M. (1988). Patterns of structural change. *Handbook of Development Economics*, 1, 203-273.
- Szandala, T. (2021). Review and comparison of commonly used activation functions for deep neural networks. In: Bhoi, A., Mallick, P., Liu, CM., Balas, V. (eds). *Bio-Inspired Neurocomputing*, 203-224. Singapore: Springer.
- Szeghalmy, S., ve Fazekas, A. (2023). A Comparative Study of the Use of Stratified Cross-Validation and Distribution-Balanced Stratified Cross-Validation in Imbalanced Learning. *Sensors*, 23(4), 2333.
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications*. Cham, Switzerland: Springer Nature.
- Tan, M., ve Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International Conference on Machine Learning* (pp. 6105-6114). California, USA.
- Tougui, I., Jilbab, A., ve El Mhamdi, J. (2021). Impact of the choice of cross-validation techniques on the results of machine learning-based diagnostic applications. *Healthcare Informatics Research*, 27(3), 189-199.
- Tong, Y., Lu, W., Deng, Q. Q., Chen, C., ve Shen, Y. (2020). Automated identification of retinopathy of prematurity by image-based deep learning. *Eye and Vision*, 7, 1-12.
- Torfi, A., Shirvani, R. A., Keneshloo, Y., Tavaf, N., ve Fox, E. A. (2020). Natural language processing advancements by deep learning: A survey. *arXiv preprint arXiv:2003.01200*.

- Varshney, M., ve Singh, P. (2021). Optimizing nonlinear activation function for convolutional neural networks. *Signal, Image and Video Processing*, 15(6), 1323-1330.
- Vázquez-Canteli, J. R., ve Nagy, Z. (2019). Reinforcement learning for demand response: A review of algorithms and modeling techniques. *Applied energy*, 235, 1072-1089.
- Verma, S., Chug, A., ve Singh, A. P. (2020). Application of convolutional neural networks for evaluation of disease severity in tomato plant. *Journal of Discrete Mathematical Sciences and Cryptography*, 23(1), 273-282.
- Veselov, G., Tselykh, A., Sharma, A., ve Huang, R. (2021). Applications of artificial intelligence in evolution of smart cities and societies. *Informatica*, 45(5).
- Vrbančič, G., ve Podgorelec, V. (2020). Transfer learning with adaptive fine-tuning. *IEEE Access*, 8, 196197-196211.
- Vujović, Ž. (2021). Classification model evaluation metrics. *International Journal of Advanced Computer Science and Applications*, 12(6), 599-606.
- Wang, H., Lei, Z., Zhang, X., Zhou, B., ve Peng, J. (2016). Machine learning basics. *Deep Learning*, 98-164.
- Wang, Q., Qi, F., Sun, M., Qu, J., ve Xue, J. (2019). Identification of tomato disease types and detection of infected areas based on deep convolutional neural networks and object detection techniques. *Computational Intelligence and Neuroscience*, 2019, 9142753.
- Wu, Z., Zhang, W. L., ve Li, C. (2022). Automatic Implementation Algorithm of Pressure Relief Drilling Depth Based on an Innovative Monitoring-While-Drilling Method. *Sensors*, 22(9), 3234.
- Yıkılmazsoy, G., ve Çetinkaya, N. (2022). Domates Küllemesi Etmeni *Oidium neolycopersici*'ye Karşı Bazı Domates Çeşitlerinin Reaksiyonlarının Belirlenmesi ve Hastalığın Mücadelesi Üzerinde Araştırmalar. *The Journal of Turkish Phytopathology*, 51(2), 31-37.
- Zhang, A., Lipton, Z. C., Li, M., ve Smola, A. J. (2023). *Dive into deep learning*. Mexico: Cambridge University Press.
- Zhang, C., ve Lu, Y. (2021). Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration*, 23, 100224.
- Zhao, T., Pei, T., Jiang, J., Yang, H., Zhang, H., Li, J., ve Xu, X. (2022). Understanding the mechanisms of resistance to tomato leaf mold: A review. *Horticultural Plant Journal*, 8(6), 667-675.
- Zhou, Z. H. (2021). *Machine Learning*. Singapore: Springer Nature.

Zhu, Z., Lin, K., Jain, A. K., ve Zhou, J. (2023). Transfer learning in deep reinforcement learning: A survey. *IEEE, Transactions on Pattern Analysis and Machine Intelligence*, 45, 13344–13362.

Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ve He, Q. (2020). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76.

