



**T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**PANCAR BİTKİ HASTALIKLARININ DERİN ÖĞRENME İLE
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

BİLAL EYİSOY

HAZİRAN

BİLAL EYİSOY

TEKNOLOJİ VE İNOVASYON
YÖNETİMİ ANABİLİM DALI

HAZİRAN 2024

**PANCAR BİTKİ HASTALIKLARININ DERİN ÖĞRENME İLE
SINIFLANDIRILMASI**

Bilal EYİSOY

**YÜKSEK LİSANS TEZİ
TEKNOLOJİ VE İNOVASYON YÖNETİMİ ANABİLİM DALI**

**Danışman
Dr. Öğr. Üyesi YAVUZ ÜNAL**

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2024

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Bilal EYİSOY tarafından hazırlanan “Pancar Bitki Hastalıklarının Derin Öğrenme ile Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Teknoloji ve İnovasyon Yönetimi Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Yavuz ÜNAL

Bilgisayar Yazılımı Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Başkan : Dr. Öğr. Üyesi Mahir KAYA

Bilgisayar Yazılımı Anabilim Dalı, Tokat Gaziosmanpaşa Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Üye : Dr. Öğr. Üyesi Canan ORAL

Devreler ve Sistemler Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Tez Savunma Tarihi: 27/06/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

(İmza)

Bilal EYİSOY

... / ... / 2024

PANCAR BİTKİ HASTALIKLARININ DERİN ÖĞRENME İLE
SINIFLANDIRILMASI
(Yüksek Lisans Tezi)

Bilal EYİSOY

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Haziran 2024

ÖZET

Şeker insan hayatı için vazgeçilmez bir öneme sahiptir. Şeker pancarı temel gıda maddesi olan şeker üretiminin haricinde diğer yan ürünleri ile tarımsal ve ekonomik açıdan büyük bir öneme sahiptir. Üretilen şekerin verimi ve kalitesini olumsuz yönde etkileyen sebeplerin başında bitkide meydana gelebilecek hastalıklar yer almaktadır. Şeker pancarında oluşan yaprak hastalıkları nedeni ile kök gelişimleri istenilen seviyelere gelememekte buda bitkinin şeker oranı ve verimini düşürmektedir. Yapraklarda oluşan hastalıkların erken dönemlerde tespit edilmesi hastalığın yayılımını veya bitkiye vereceği zararı en aza indirmektedir. Hastalıkların tespitinde gelişen teknoloji ile beraber görüntü ve nesne algılama için derin öğrenme yöntemleri kullanılmaktadır. Bu modeller arasında sürekli güncellenen versiyonları ve artan kullanım alanları ile YOLO (You only look once) dikkat çekmektedir. Bu çalışmada YOLOv8, ResNet50 ve DenseNet121 modelleri kullanılarak ülkemizde yaygın olarak görülen şeker pancarı hastalıklarından cercospora (yaprak lekesi), powdery mildew (külleme) hastalıklarının sınıflandırılması incelenmiştir. YOLOv8'in alt modelleri ile yapılan sınıflandırma işlemleri ile ResNet50 ve DenseNet121 transfer öğrenme modellerinin eğitim sonuçları performans değerlendirme kriterlerine göre karşılaştırılmıştır.

Sayfa Adedi	: 56
Anahtar Kelimeler	: Derin öğrenme, şeker pancarı, bitki hastalıkları
Danışman	: Dr. Öğr. Üyesi Yavuz ÜNAL

CLASSIFICATION OF BEET PLANT DISEASES USING DEEP LEARNING
(M. Sc. Thesis)

Bilal EYİSOY

AMASYA UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES
June 2024

ABSTRACT

Sugar has an essential importance for human life. As a staple food, sugar beet has great agricultural and economic importance with its other by-products besides sugar production. The main reasons that negatively affect the yield and quality of the sugar to be produced are the diseases that may occur in the plant. Due to leaf diseases in sugar beet, root development cannot reach the desired levels, which reduces the sugar content and yield of the plant. Detecting diseases in the leaves at an early stage minimizes the spread of the disease or the damage to the plant. In the detection of diseases, deep learning methods are used for image and object detection along with advancing technology. Among these models, YOLO (You Only Look Once) attracts attention with its constantly updated versions and increasing usage areas. In this study, the classification of *Cercospora* (leaf spot) and powdery mildew diseases, which are common sugar beet diseases in our country, were examined by using YOLOv8, ResNet50, and DenseNet121 models. With the classification processes performed with YOLOv8 submodels, the training results of ResNet50 and DenseNet121 transfer learning models were compared according to performance evaluation criteria.

Number of pages : 56
Keywords : Deep learning, sugar beet, plant diseases
Supervisor : Asst. Prof. Dr. Yavuz ÜNAL

ÖN SÖZ VE TEŞEKKÜR

Tez çalışmamda bilgi ve deneyimlerinden yararlandığım, araştırmam boyunca yardımlarını esirgemeyen ve sürekli destek olan tez danışmanım sayın Dr. Öğr. Üyesi Yavuz Ünal'a teşekkür ederim.

Yüksek Lisans eğitimim süresince beni destekleyen, her zaman yanımda olan sevgili eşim Serpil EYİSOY'a, kıymetlilerim ve neşe kaynağım olan kızlarım Melinay Nisa ve Elif Azra EYİSOY'a, varlığı ile bana güç veren babam Sadettin EYİSOY ve annem Cevriye EYİSOY'a anlayış, destek ve sabırları için teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
ÖN SÖZ VE TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
RESİMLER DİZİNİ	xii
1. GİRİŞ.....	1
1.1. Literatür Taraması	3
2. PANCAR BİTKİSİ	8
2.1. Şeker Pancarı Bitkisi Yaprak Hastalıkları	12
2.1.1. Cercospora yaprak lekesi.....	12
2.1.2. Külleme hastalığı	14
3. KURAMSAL TEMELLER	16
3.1. Yapay Zekâ	16
3.2. Makine Öğrenmesi.....	17
3.3. Yapay Sinir Ağları.....	18
3.3.1. Yapay sinir ağlarının yapısı	20
3.3.2. Yapay sinir ağı sınıflandırılması	20
3.4. Derin Öğrenme	21
3.5. Evrişimli/Konvolüsyonel Sinir Ağları (Convolutional Neural Networks – (CNN)).....	22
3.5.1.Evrişim katmanı	24

3.5.2. Havuzlama katmanı.....	25
3.5.3. Tam bağı katman.....	25
3.6. Nesne Algılama Modelleri	26
3.6.1. R-CNN.....	26
3.6.2. Fast R-CNN	27
3.6.3. Faster R-CNN	27
3.6.4. Mask R-CNN	28
3.6.5. SSD (Single shot multibox detector).....	29
3.6.6. ResNet (Residual Network).....	30
3.6.7. DenseNet (Dense Convolutional Network).....	30
3.6.8. YOLO (You Only Look Once).....	31
4. MATERYAL VE YÖNTEM	35
4.1. Nesne Sınıflandırma ve Nesne Tespiti.....	35
4.2. Veri Setinin Oluşturulması.....	36
4.3. Kullanılan Yazılımlar ve Kütüphaneler	38
4.4. Performans Metrikleri.....	41
5. DENEYSEL BULGULAR.....	43
5.1. YOLOv8x-cls Modeli Sınıflandırma Sonuçları	44
5.2. YOLOv8l-cls Modeli Sınıflandırma Sonuçları	45
5.3. YOLOv8m-cls Modeli Sınıflandırma Sonuçları	46
5.4. DenseNet121 Modeli Sınıflandırma Sonuçları	47
5.5. ResNet50 Modeli Sınıflandırma Sonuçları	48
6. SONUÇ VE ÖNERİLER.....	49
KAYNAKLAR	56
ÖZGEÇMİŞ	56

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 2.1. Şeker pancarı dünyada üretim miktarı dağılımı (Kanat, 2023).....	10
Çizelge 2.2. Türkiye’de şeker pancarı ekim, üretim ve verim miktarı.	10
Çizelge 4.1. Sınıflandırma işlemi için kullanılan görüntü sayıları	36
Çizelge 5.1. YOLOv8 modellerinin ImageNet veriseti başarımları	43
Çizelge 5.2. Eğitimde kullanılan modeller ve doğruluk-accuracy sonuçları	43
Çizelge 5.3. YOLOv8x-cls modeli eğitim sonuçları	45
Çizelge 5.4. YOLOv8l-cls modeli eğitim sonuçları	46
Çizelge 5.5. YOLOv8m-cls modeli eğitim sonuçları	47
Çizelge 5.6. DenseNet121 modeli eğitim sonuçları.....	48
Çizelge 5.7. ResNet50 modeli eğitim sonuçları	48

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 2.1. Dünya üzerindeki şeker kamışı ve şeker pancarı üretimi (Kanat, 2023).....	9
Şekil 2.2. Cercospora Beticola'nın yaşam döngüsü (Esmer, 2009).....	14
Şekil 3.1. Yapay zekâ gelişim süreci	17
Şekil 3.2. Makine öğrenmesi genel yapısı (İstanbulu, 2022)	18
Şekil 3.3. Yapay sinir ağlarının genel yapısı (Sargın ve Göçen, 2023)	19
Şekil 3.4. Makine öğrenmesi ve derin öğrenme (Sargın ve Göçen, 2023).....	22
Şekil 3.5. Örnek evrişimli sinir ağı (Ergin, 2018).....	23
Şekil 3.6. CNN çalışma örneği 1 (Rohrer, 2016).....	23
Şekil 3.7. CNN çalışma örneği 2 (Rohrer, 2016).....	23
Şekil 3.8. Öznetelik hesaplama işlemi (Akdoğan, 2020).....	24
Şekil 3.9. En büyük ve ortalama havuzlama işlemi (Koç, 2022).....	25
Şekil 3.10. Tam bağlı katman yapısı (Karacan, 2024).	26
Şekil 3.11. R-CNN algoritma yapısı.	26
Şekil 3.12. Fast R-CNN mimarisi (Girshick, 2015).....	27
Şekil 3.13. Faster R-CNN mimarisi (Meşeci, 2021).....	28
Şekil 3.14. Mask R-CNN genel mimarisi (Gonzalez, Arellano, ve Tapia, 2019)	29
Şekil 3.15. Single shot multibox detector (SSD) mimarisi (Başarır, 2019)	30
Şekil 3.16. YOLO ve diğer modellerin hız karşılaştırılması	31
Şekil 3.17. YOLO algoritmasının çalışma mantığı (Tekin, 2019).....	33
Şekil 3.18. YOLO temel mimarisi (Keita, 2022).....	33
Şekil 3.19. YOLO sürümlerinin gelişimi	34
Şekil 4.1. Sınıflandırma işlemi klasör yapısı	36
Şekil 4.2. Şeker pancarı yaprak hastalıkları tespiti akış şeması.....	38

Şekil 4.3. YOLOv8 genel mimarisi (Herfandi, Sitanggang, Nasution, Nguyen, ve Jang, 2024).	39
Şekil 4.4. YOLO nesne tespit işlemi	39
Şekil 4.5. Hiperparametre dosyası içeriği.....	40
Şekil 4.6. Karışıklık matrisi (Confusion matrix)	41
Şekil 5.1. YOLOv8x-cls, YOLOv8l-cls ve YOLOv8m-cls modellerine göre train/loss (eğitim/kayıp) değerleri.....	44
Şekil 5.2. YOLOv8x-cls karışıklık matrisleri.....	45
Şekil 5.3. YOLOv8l-cls karışıklık matrisleri.....	46
Şekil 5.4. YOLOv8m-cls karışıklık matrisleri.....	47

RESİMLER DİZİNİ

Resim	Sayfa
Resim 1.1. Cercospora yaprak lekesi ve külleme hastalıkları	2
Resim 2.1. Şeker pancarı bitkisi	8
Resim 2.2. Şeker Pancarı bitkisi ekimi (Soylu, 2011)	11
Resim 2.3. Cercospora yaprak lekesi hastalığı	13
Resim 2.4. Şeker pancarı külleme hastalığı.....	15
Resim 4.1. Nesne sınıflandırma ve nesne tespiti	35
Resim 4.2. Sınıflandırma işlemi için kullanılan veri setinden görüntü.....	37

SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir.

Kısaltmalar	Açıklama
CNN	Convolutional Neural Network
DESA	Derin Evrişimsel Sinir Ağı
ESA	Evrişimsel Sinir Ağı
VGG	Visual Geometry Group
YSA	Yapay Sinir Ağı
LTSM	Long Short Term Memory
DVM	Destek Vektör Makinesi
RPN	Region Proposal Network
RoI	Region of Interest
YOLO	You only look once
GPU	Graphics Processing Unit
CPU	Central Process Unit
ReLU	Rectified Linear Units
TN	Doğru Negatif
TP	Doğru Pozitif
TN	Doğru Negatif
TN	Doğru Negatif
RPN	Bölge Önerme Ağı
FC	Fully Connected

1. GİRİŞ

Tarım insan hayatı için vazgeçilmez bir öneme sahiptir. Tarımsal ürünlerden elde edilen mahsullerin kalitesinin ve verimliliğin artması günümüz dünyasında artan nüfus ve iklim farklılaşmalarından kaynaklanan olumsuz etkenlerin ortaya çıkarmış olduğu sorunları azaltması açısından da önlem alınması ve çözülmesi gereken sorunların başında gelmektedir (Karadeniz, 2023). Tarım sektörünü etkileyen en büyük olumsuzlukların başında elde edilecek ürünlerin veriminin düşmesi ve buna paralel olarak da gelirin azalması, bu olumsuzlukları ortadan kaldırmak için harcanacak emek, zaman ve ekonomik giderlerin artması gelmektedir (Altaş, Özgüven, ve Yanar, 2019).

Bitki ve meyvelerdeki verim sorununun başlıca sebeplerinden biride ortaya çıkan hastalıklardır. Bu sorunu en aza indirip verimliliğin artması için hastalıkların erken teşhisi, sorunun yayılmasını ve vereceği hasarları azaltacaktır. Günümüzde çiftçiler hastalık tespiti için kendi gözlem ve tecrübelerine göre hareket ederek önlem almaktadır. Büyük alanlarda ekim yapılan yerlerde bitki yapraklarının kontrol edilmesi için çok sayıda eleman ve zaman ihtiyacı ortaya çıkmaktadır. Tespit işlemi için bu kadar zaman ve emek harcamak yerine gelişen teknolojinin sağlamış olduğu faydalardan yararlanılarak derin öğrenme ve nesne tespit uygulamaları kullanılmaya başlanmıştır (Bozcu, 2024).

İnsanlar için temel besin maddelerinin başında gelen şeker ihtiyacı tarihte farklı tarım mamullerinden çeşitli yöntemlerle üretilmiştir. Amerika'nın keşfi ile şeker kamışından üretilmeye başlayan şeker, şeker kamışının yetiştirilmesi için gerekli olan iklim koşullarının diğer kıtalarda uygun olmaması ya da istenilen verimin elde edilememesi sebebiyle şeker pancarından elde edilmeye başlanmıştır (Bulut, 2006). Besin ve enerji kaynağı olarak insan hayatının vazgeçilmezleri arasında olan şeker devletler açısından da kritik bir öneme sahiptir. Şeker sadece besin kaynağı olarak değil bunun yanı sıra birçok üretim malzemesinin ham maddesini sağlamaktadır. Köyden kente göçü engellemesi, ülke ekonomilerine sağlamış olduğu faydalar, devletlerin kendi kendilerine yetebilme siyasetini desteklemesi açısından da politik bir öneme sahiptir (Fedai, 2016).

Hükümetler ve insan hayatı için son derece yüksek öneme sahip şeker üretiminin sağlandığı şeker pancarından mümkün olduğunca yüksek verim alabilmek ya da bu durumu olumsuz

etkileyebilecek nedenlerle de doğru mücadele de önemlidir. Şeker pancarında ekili alanlarda verimi ve elde edilecek şekerin kalitesini etkileyen en önemli sebep bitki hastalıklarıdır. Bitki hastalıkları ile doğru ve planlı bir mücadele için erken teşhis ve gerekli tedbirleri almak gerekmektedir.

Bu tezde ele aldığımız pancar bitkisinin verimini olumsuz yönde etkileyen problemlerin başında pancar bitkisi yapraklarında ortaya çıkan Cercospora yaprak lekesi ve Külleme hastalıkları gelmektedir. Hastalıklı yapraklara ait görüntüler Resim 1.1.'de görülmektedir. Her iki hastalıkta da yeterli tedbir ve önlemler alınmaması durumunda hastalığın ilerleyen seviyelerinde yaprakların kuruyup dökülmesine neden olarak bitkinin kök gelişimini olumsuz açıdan etkilemektedir bu da istenilen seviyede verim alınmasına engel olmaktadır (Özgür, 2003).



Resim 1.1. Cercospora yaprak lekesi ve külleme hastalıkları

Bu çalışmamızdaki amaç pancar bitki yapraklarında oluşan hastalıkların tespiti için son zamanlar da nesne tespit işlemlerinde yaygın bir şekilde kullanılan YOLO derin öğrenme modeli ile ResNet50 ve DenseNet121 transfer öğrenme modelleri ile hastalıklı yaprakların sınıflandırılmasını gerçekleştirmektir. Çalışmanın bundan sonraki bölümlerinde ilk olarak pancar ve diğer bitki hastalıklarının tespiti için daha önceden yapılmış olan çalışmaların

araştırıldığı literatür taraması, pancarın ülke ve dünya ekonomisi açısından önemi ve pancar bitki hastalıklarının açıklandığı pancar bitkisi bölümü, görüntülerde nesne tespiti için algoritma ve modellerin açıklandığı materyal metot bölümü, veri setimizin üzerinde uygulanan YOLO modellerinin eğitim sonuçlarının yer aldığı eğitim ve test sonuçları bölümü ve son olarak da elde edilen sonuçların değerlendirildiği sonuç bölümü yer almaktadır.

1.1 Literatür Taraması

Yaptığımız araştırmanın bu bölümünde derin öğrenme yöntemleri kullanılarak şeker pancarı yaprağı ve diğer bitki yaprak hastalıklarının belirlenmesinde yerli ve yabancı literatürde yapılan çalışmaların bir kısmı sunulmuştur.

Hallau ve arkadaşlarının şeker pancarında verimi olumsuz etkileyen en önemli faktörlerden biri olan cercospora yaprak lekesi hastalığını tespit etmek için yaptıkları çalışmada yaprak lekesi hastalığının 5 türünü Destek Vektör Makinesi (DVM) kullanarak sınıflandırmışlar ve gerçekleşen eğitim sonuçlarında ise %82'lik bir başarımlık değeri elde etmişlerdir (Hallau ve diğerleri, 2018).

Doğan ve Türkoğlu 32 sınıftan oluşan 1900 yaprak içeren veri setini temel alan çalışmalarında örnek sayısını arttırmak için yansıma ve tersleme işlemlerini kullanarak örnek sayılarını 7600'e çıkarmış ve bu görüntüler üzerinde derin öğrenme modellerinden olan AlexNet, Vgg16, Vgg19, ResNet50, GoogleNet gibi algoritmalar ile sınıflandırma işlemi yaparak %97,77 ile %99,72 arasında başarılı sonuçlar elde etmişlerdir (Doğan ve Türkoğlu, 2018).

Özgüven ve Âdem'in şeker pancarı yaprak lekesi hastalığının belirlenebilmesi için geliştirdikleri Region based Convolutional Neural Networks (R-CNN) temelli modelde 155 resim ile eğitim gerçekleştirmiş ve %95,48'lik bir başarımlık oranı elde etmişlerdir. Elde edilen bu sonuç önceden yapılmış çalışmalara göre daha başarılı olmuştur (Özgüven ve Adem, 2019).

Altaş ve arkadaşlarının görüntü işleme tekniklerini kullanarak yaptıkları çalışmada şeker pancarı yaprak lekesi görüntülerini hem uzmanların hem de kendi geliştirdikleri sistemin

sonuçlarını karşılaştırdıklarında hastalıklı alanların görüntü işleme teknikleri ile kesin olarak belirlendiğini ve hastalık tespiti için bu sistemlerin tercih edilebileceğini belirtmişlerdir (Altaş ve diğerleri, 2019).

Gao ve ekip arkadaşlarının şeker pancarı üretim bölgelerinde çit sarmaşığı yabancı otunu tespit etmek için yaptıkları çalışmada 452 resimi veri arttırma tekniklerini kullanarak 2 271'e kadar yükseltmiş ve geliştirdikleri Convolutional Neural Networks (CNN) modeli üzerinde yapılan eğitim sonucunda %82,9'luk bir doğrulama oranı elde etmişlerdir (Gao ve diğerleri, 2020).

Türkoğlu, Hanbay, Sivrikaya ve Hanbay'ın kayısı hastalıklarının tespiti için Derin Evrişimsel Sinir Ağı (DESA)'na dayalı önerdikleri ve içerisinde evrişim, relu, normalizasyon, havuzlama ve tam bağlı katmanların olduğu model ile yaptıkları çalışmada farklı filtre çeşitleri ile deneysel uygulamalar gerçekleştirmiş elde edilen sonuçlara göre de yaptıkları test sonuçlarının geleneksel görüntü tanımlayıcılara göre daha iyi sonuçlar ve başarılı sınıflandırma ile sonuçlandığını belirtmişlerdir (Türkoğlu, Hanbay, Sivrikaya, ve Hanbay, 2020).

Muzaffer tarafından yapılan derin öğrenme ile şeftali hastalıklarının tespiti isimli çalışmalarında CNN yapısı kullanarak sağlıklı olanların belirlenmesini sağlayan bu yöntemde daha önceden eğitilen AlexNet modeli üzerinden şeftali ağaçlarında rastlanan monilya ve koşnili hastalıklarının belirlenmesi sağlanmıştır. Çalışma sonucunda %99,30 luk bir doğruluk oranı elde edilmiş ve bunun daha önce yapılan çalışmalara göre %1,44'lük oranda daha başarılı olduğu saptanmıştır (Muzaffer, 2021).

Çetiner elma yapraklarında gelişen hastalıkları erken evrede teşhis etmek için Evrişimsel Sinir Ağları (CNN) yapısını kullanarak transfer öğrenim tekniklerinden olan DenseNet201, MobileNetV2, ResNet50V2, ResNet101V2, ResNet152V2 algoritmaları temel alan modeller üzerinde yaptıkları çalışmada kullanılan veri setinin zorluk seviyesinin yüksek olmasına rağmen %97'lik bir doğruluk oranı elde etmişlerdir (Çetiner, 2021).

Yaman ve Tuncer'in çalışmalarında bitki yapraklarındaki hastalıkların tespiti için derin öğrenme ve özellik seçimi yöntemi kullanmış, araştırma için seçilen ceviz bitki yapraklarından 726 görüntü toplanmıştır. Yapraklar sağlıklı ve hastalıklı olarak iki sınıfa

ayrılmış ve 17 adet derin öğrenme algoritması ile test edilerek elde edilen sonuçlardan en başarılı iki model seçilmiştir. Seçilen modeller olan DarkNet53 ve ResNet101 'den üretilen sonuçlar birleştirilip geliştirdikleri hibrit model ile %99.58'lik doğruluk sonucuna ulaşmışlardır (Yaman ve Tuncer, 2022).

Esen ve Onan'ın Mendeley Plant Diseases Dataset'ini kullanarak bitki yapraklarının hastalıklarını sınıflandırmayı amaçladıkları çalışmada en başarılı sonucu %94.88 ile VGG16 modeli ile elde etmişlerdir. Aynı çalışma sonuçlarına göre VGG16 mimarisinin eğitim süresinin DenseNet ve EfficientNetB0'a göre daha düşük olduğunu belirtmişlerdir. Düşük donanımlı cihazlarda eğitim test işlemi içinse MobileNetV2'nin tercih edilebileceğini vurgulamışlardır (Esen ve Onan, 2022).

Sevli 3 farklı hastalığı ve birde sağlıklı yaprakların içinde bulunduğu 1821 adet resimden oluşan veri seti üzerinde yaptığı çalışmada önermiş olduğu Evrişimsel Sinir Ağı (ESA) modeli ile elma yaprak hastalıklarının sınıflandırılması işlemi gerçekleştirmiş ve sonuç olarak da %98'den büyük doğruluk değerleri elde etmiştir (Sevli, 2022).

Karahanlı ve Taşkın'ın ayçiçeği bitkisinin büyüme dönemlerinin sınıflandırılmasına yönelik yaptıkları çalışmada Dron kullanarak elde ettikleri görüntüler üzerinden 8 sınıf oluşturmuş ve 12 800 adet resimlik büyük bir veri seti elde etmişlerdir. Bu veri setini AlexNet, InceptionV3, ResNet101, DenseNet121, MobileNet ve Xception derin öğrenme algoritmaları ve Sgd, Adam ve Rmsprop optimizasyon yöntemleri ile test ederek başarımlarını karşılaştırmıştır. Oluşan sonuçlara göre en iyi performansı %93,98'lik oranla ResNet101 modeli göstermiştir (Karahanlı ve Taşkın).

Güneş çalışmasında VGG16, InceptionV3 ve Resnet50 modellerini kullanarak fındık meyvesinin sınıflandırılmasını yapmıştır. Kullanılan veri setine göre VGG16 %99, InceptionV3 %96 ve Resnet50 modeli ise %89'a yakın eğitim sonuçları üretmiştir. Aynı veri setinin boyutlarının düşürerek yine aynı modeller üzerinde eğitim gerçekleştirmiş ve ilk elde edilen sonuçlara göre başarımlarının düştüğü tespit edilmiştir (Güneş, 2022).

İpek domates yapraklarındaki hastalıkların sınıflandırılması için yaptığı çalışmada ESA modellerinden GoogleNet, AlexNet, SqueezeNet, ShuffleNet ve ResNet-18'i

uygulamasında kullanmış ve en yüksek doğruluk oranının %93,93 ile AlexNet, en düşük doğruluk oranının da %81,79 ile ResNet-18 ile bulunduğunu belirtmiştir (İpek, 2022).

Dikici, Bekçioğulları, Açıkgöz ve Korkmaz'ın AlexNet, GoogleNet, ShuffleNet ve SqueezeNet derin öğrenme modellerinin uygulandığı çalışmada zeytin yaprağındaki hastalıkların teşhisi ve sınıflandırma işlemini gerçekleştirmişlerdir. Veri setindeki resimler veri artırma yöntemleri ile çoğaltılmış ve daha çok zeytin yaprağı resmi elde edilmiştir. İlk veri seti üzerinden yapılan eğitimde ShuffleNet'in artırılmış resimlerin bulunduğu veri setinde de SqueezeNet'in en yüksek başarı oranları elde ettiği görülmüştür (Dikici, Bekçioğulları, Açıkgöz, ve Korkmaz, 2022).

Andaç, Doğan, Şengür ve Ergen'in 5 farklı asma yaprak türü üzerinde 500 resimden oluşan veri seti üzerinde yaptıkları çalışmada ilk olarak resim sayısını veri artırma teknikleri ile 3 500'e kadar çoğaltmışlardır. Bu resimler üzerinde ESRGAN modeli uygulanarak elde edilen nitelikli resimler VGG19 derin öğrenme algoritması üzerinden elde ettikleri öznelitliklerin sınıflandırılması için DVM kullanarak %96,14'lük doğruluk sonucuna ulaşmışlardır (Andaç, Doğan, Şengür, ve Ergen, 2023).

Terzi, Özgüven ve Yağcı tarafından Corint, Merlot, Tayfi, Narinceve Michele palieri üzüm türlerinin salkım ve meyve görüntülerini kullandıkları sınıflandırma çalışmasında 1028 resim kullanılmış ve 15 katmanlı bir derin öğrenme algoritması üzerinde eğitim gerçekleştirmiştir. Elde edilen sonuçta kullanılan modelin doğruluk oranı %96,10 olarak belirtilmiş ve bu çalışmanın diğer çalışmalara göre daha başarılı sonuçlar ettiği söylenmiştir (Terzi, Özgüven, ve Yağcı, 2023).

Kılıçaslan ve Pacal DenseNet, ResNet50 ve MobileNet modellerini kullanarak yaptıkları çalışmada eğitim sonuçlarını hata, doğruluk, kesinlik, f1-skor ve duyarlılık parametrelerine göre değerlendirme yapmışlardır. Elde edilen bu sonuçlara göre en başarılı performansı DenseNet modeli gerçekleştirmiş, derin öğrenme algoritmalarının domates bitkisinin yaprağında oluşan rahatsızlıkların sınıflandırılmasında doğruluk oranlarının yüksek olduğunu belirtmişlerdir (Kılıçaslan ve Pacal, 2023).

Bozcu kiraz yapraklarındaki hastalıkların tespiti için iki ayrı veri setindeki yaprak örnekleri ile derin öğrenme algoritmalarının performanslarını incelemiştir. Elde edilen sonuçlara göre

en iyi performansı MobileNet-V2 ve önerdikleri CNN+LSTM modelleri sergilemiştir (Bozcu, 2024).



2. PANCAR BİTKİSİ

Şeker, geçmişten günümüze kadar insanlar için en önemli besin maddelerinden olmuş, şeker üretimi içinse 18'inci yüzyıla kadar genellikle şeker kamışı kullanılmıştır. Şeker pancarındaki şeker 18'inci yüzyılda Almanya'da gerçekleştirilen çalıştırmalardan sonra ortaya çıkmıştır. Yapılan bu çalışmalar ışığında şeker pancarından şeker üretilme süreci şeker kamışından şeker elde etmeye göre maliyetli olmasından dolayı şeker pancarı fabrikalarının kurulumu ancak 19'uncu yüzyıla beraber gerçekleşmiştir. Bu gelişmeyle beraber şeker kamışı yetiştiriciliğinde sıkıntı yaşayan Avrupa coğrafyası şeker üretimi için şeker pancarına yönelmiştir (Koday ve Yıldırım, 2021).

Dünya üzerinde 120'den fazla ülkede üretilen şeker yiyecek içecek sektörünün en temel öğelerinden biridir (Resim 2.1). Besin maddeleri içinde kalori olarak en üst değerlerden birine sahip olan şekerin üretilmesi ülkeler açısından yüksek öneme sahiptir. Gıda sektöründe nerdeyse kullanılmadığı alan olmayan şeker toplumların ekonomik gelişim ve değişimlerinin yanı sıra diğer ülkeler ile de olan ticari ilişkilerinde önemli bir role sahiptir (Demirdöğen, 2022).




Resim 2.1. Şeker pancarı bitkisi

Şekerin gıda endüstrisinin vazgeçilmez temel elemanlarından biri olmasının en büyük etkenleri arasında endüstri devrimi ile beraber köyden şehire göçlerin hızlanması ve şehir

nüfuslarının artması, buna bağlı olarak hazır ve kolay tüketilebilen gıda ihtiyacının yükseliş göstermesi gelmektedir. Sadece yiyecek alanının değil aynı zamanda içecek sektörünün de temel bileşenlerinden olan şeker günlük hayatın vazgeçilmez ihtiyaçlarından biri haline gelmiştir (Yücel, 2023). Kullanım alanının ve şekere duyulan ihtiyacın endüstri devrimi ile beraber doğru orantılı olarak artış göstermesi şeker kamışı yerine şeker pancarından şeker üretimini ve buna bağlı olarak şeker pancarı ekimini arttırmıştır. Bu denli artış gösteren şeker ihtiyacını karşılamakta ülkeler açısından stratejik öneme sahiptir.

Şeker pancarı tarım faaliyetleri arasında diğerlerine göre daha fazla çaba ve emek isteyen bir üründür. Şeker pancarı tarımından elde edilecek verimin yüksek olması için iklim ve toprak koşulları büyük öneme sahip olsa da tek başına yeterli değildir. İklim ve toprak şartlarının uygun olmasının yanı sıra ekim yapılacak tarlanın hazırlanması, ürünlerin bakım, gübreleme, sulama ve ekilecek tohumun doğru seçilmesi gibi şeker pancarı verimini doğrudan etkileyecek faktörlere yeteri kadar önem verilmediği zaman istenen verimi elde etmek mümkün değildir (Aytüre ve Demir, 2008).

Şekerin kalitesi bakımından şeker pancarı ya da şeker kamışı olmasının herhangi bir farkı yoktur. Üretilen şekerin çoğunluğunun şeker kamışından elde edilmesinin en büyük nedeni yalnızca tropik ve alt tropik alanlarda ekimi gerçekleştirilen şeker kamışının daha az üretim ve işletme maliyetine sahip olmasıdır (Kaya, 2015). Dünya üzerindeki şekere duyulan gereksinimin yaklaşık %21'i şeker pancarından geriye kalan %79'luk bölümü ise şeker kamışından karşılanmaktadır (Şekil 2.1).



Şekil 2.1. Dünya üzerindeki şeker kamışı ve şeker pancarı üretimi (Kanat, 2023)

Üzerinde bulunduğu coğrafi yapıdan dolayı Türkiye, Avrupa Birliği, Rusya, Ukrayna gibi ülkeler şeker pancarından, ABD, Japonya, Çin hem şeker kamışı hem de şeker pancarından, Brezilya, Avustralya, Hindistan, Meksika gibi ülkeler ise şeker kamışından şeker üretimi yapmaktadırlar (Çizelge 2.1). Ülkemizde tarım alanındaki üretimde en temel ürünlerden biri olan şeker pancarı her sektör açısından büyük bir önem arz etmektedir. Kullanım alanı çok geniş olan şeker ihtiyacı cumhuriyet dönemine kadar ithalat yöntemi ile giderilmekteydi. Cumhuriyet sonrasında ise ülkemizde çiftçiye verilen destekler ve gerçekleşen yatırımlar ile şeker ihtiyacının tümünü kendimiz karşılayacak durumu gelinmiştir (Türkşeker, 2021).

Çizelge 2.1. Şeker pancarı dünyada üretim miktarı dağılımı (Kanat, 2023)

Ülke	Ekim Alanı (bin ha)	Üretim (bin ton)	Verim (ton/ha)
Rusya	994	41 202	41,5
ABD	448	33 340	74,4
Fransa	402	34 365	85,5
Almanya	391	31 945	81,8
Türkiye	289	18 250	63,2
Polonya	251	15 274	61,0
Çin	229	7 851	34,2
Ukrayna	227	10 854	47,9
Mısır	190	14 827	78,0
İngiltere	95	7 420	77,9
Diğer	1 113	62 679	77,9
Dünya	4 629	278 007	60,1

Ülkemizde 2022 senesinde 19 milyon ton şeker pancarı üretilmiş ve ekim alanında 3 milyon dekar alan olmuştur. Üretilen bu şeker pancarı miktarından ise elde edilen şeker üretimi ise 2 milyon 520 bin ton olarak gerçekleşmiştir (Çizelge 2.2) (Türkşeker, 2021).

Çizelge 2.2. Türkiye’de şeker pancarı ekim, üretim ve verim miktarı.

Yıllar	Hasat Edilen Alan (bin da)	Üretim (bin ton)	Ortalama Verim (ton/da)
2011	2 938	17 942	5,46
2012	2 802	16 126	5,49
2013	2 909	14 920	5,33
2014	2 875	16 489	5,67
2015	2 740	16 743	5,82
2016	3 220	16 023	5,85
2017	3 389	19 593	6,09
2018	2 907	21 149	6,24

Çizelge 2.2. (devamı)

2019	3 101	17 436	6,00
2020	3 363	18 054	5,82
2021	3 023	23 026	6,85
2022	2 954	17 767	5,88

Şeker pancarı üretimi ve buna bağlı olan sanayi sektöründeki sağlamış olduğu istihdam ile ülke nüfusumuzun yaklaşık olarak %12'si (10 milyon) üzerinde direkt ve dolaylı olarak etkisi olmaktadır. Gıda ve hayvancılık sektörleri başta olmak üzere ilaç, et, süt ve nakliye gibi birçok iş alanı ile neredeyse iç içe geçmiş olan şeker sanayi gündelik hayatında bir parçası haline gelmiştir. Şeker pancarı üretiminin ülkemizin vazgeçilmez sanayi ve tarım sektörü olmasını sadece ekonomik alandaki sağlamış olduğu katkı ile sınırlandırmak doğru değildir (Resim 2.2). Şeker pancarı ekimi, bakımı ve depolama gibi etkenleriyle çiftçiye tarlaya bağlaması sebebiyle köyden şehire göç dengesi üzerinde de önemli bir etkisi olmakla beraber çiftçilerin sanayi alanında kopmamaları ve sürekli etkileşimde olmaları bakımından da büyük bir öneme sahiptir (Gök, 2011).



Resim 2.2. Şeker Pancarı bitkisi ekimi (Soylu, 2011)

Şeker pancarı üretiminin ülkemizin ekonomisine sağlamış olduğu faydalardan bazılarını kısaca özetlemek gerekirse (Tosun, 2015) :

- Şeker pancarı hava, güneş ve sudan elde ettiği enerjiyi bünyesinde barındırarak şeker oluşturur. Oluşan bu şeker yiyecek ve enerji bakımından büyük bir öneme sahiptir.

- Şeker pancarının şurubundan biyo-yakıt ve şeker pancarı bitkisinin köklerinden elde edilen küspe ise hayvanlar için yem olarak kullanılmaktadır.
- Tarım alanının vazgeçilmezlerinden biri olan gübrenin de %10'u şeker pancarı üretiminde kullanılmaktadır.
- Şeker pancarı tarımının büyük alanlarda yapılması, ekilen bitkiden elde edilen katma değer yüksek olması nedeniyle köyden şehire göçü önlemektedir.
- Şeker pancarından elde edilen şurup yenilenebilir enerjinin kaynağı olan biyo-etanolün en temel yapıtaşlarından biridir.

2.1. Şeker Pancarı Bitkisi Yaprak Hastalıkları

Şeker pancarının yukarıda belirttiğimiz açıklamalar ışığında ülke ekonomisi ve sanayisi için vazgeçilmez bir yapı taşı ve önemli bir etken olduğu anlaşılmaktadır. Şeker pancarından elde edilecek bu katma değer yapısını koruması ya da daha da büyüyerek etki alanının artması için üretilen ürünün kalitesinin artması gerekmektedir. Tarım ürünlerinin kalitesinin artmasını etkileyen en önemli nedenlerden biriside bitkilerde oluşabilecek hastalıklardır.

Ülkemizde şeker pancarı üretim bölgelerinde tespit edilen ve ekonomik açıdan olumsuz yönde etkileyen en önemli şeker pancarı yaprak hastalıkları Cercospora yaprak lekesi ve külleme olarak tespit edilmiştir (Özgür, 2011).

2.1.1. Cercospora yaprak lekesi


Cercospora yaprak lekesi hastalığının tanımını ilk olarak Saccardo (1876) yapmıştır. Hastalığın etken maddesi sadece şeker pancarına değil bunun yanı sıra ıspanak, sirken, sinir otu gibi yabancı ot türlerinde de hastalığa neden olmaktadır (Resim 2.3). Cercospora yaprak lekesi hastalığı şeker pancarı üzerinde ürünün randıman ve nitelikleri bakımından en çok zararı veren hastalık olarak bilinmektedir. Hastalık özellikle ılık ve nemli alanlarda etkili olmaktadır. Cercospora yaprak lekesi hastalığı ile yeteri kadar etkin bir mücadele yapılmadığı zaman hastalık ürünün kök randımanını %28, şeker oranını %13, işlenmiş şeker oranını %18 ve şeker randımanını %55'e yaklaşan seviyelerde eksiltmektedir. Hastalıkla

mücadele için en etkili yöntemler arasında hastalığa dirençli ürün yetiştirilmesi, uygun seviyede gübre ve sulama yapma ayrıca ilaçlama gelmektedir. Hastalık genetik yapısındaki değişkenlikler nedeni ile mücadele için kullanılan yöntemlere karşı dayanıklılık geliştirirken aynı zamanda uygulanan yöntemlerin dirençlerinin de azalmasına neden olmaktadır. Bu olumsuzlukların önüne geçebilmenin en önemli etkeni ilaçlamanın doğru zamanda yapılması ve erken teşhis gelmektedir (Sunulu ve Sunulu, 2016).



Resim 2.3. Cercospora yaprak lekesi hastalığı

Şeker pancarına en büyük zararı veren hastalık olarak kabul edilen Cercospora yaprak leke hastalığıdır (Weiland ve Koch, 2004). Şeker pancarı hasatından sonra ekim bölgelerinde kalan bitki artıkları 1-4 ay zaman aralığında canlılıklarını sürdürürken buradaki sporların şiddetli yağmur, rüzgâr ile tarla üzerinde yayılımını gerçekleştirmektedir. Şeker pancarı yaprakları üzerine yerleşen sporlar hava sıcaklık ve nem oranlarına bağlı olarak yaprak içinde gelişimini devam ettirmektedir (Özgür, 2003). Hastalığın şeker pancarı yaprakları üzerindeki belirtileri Mayıs ve Haziran aylarında bitkinin erken çıkan yaprakları üzerinde görülmektedir. Hastalık oluştuktan sonra ekim alanının çeşitli bölgelerinde görülüp bu durum hastalığın tarlanın tamamına yayılmasında önemli bir etkiye sahiptir (Şekil 2.2). Pancar yapraklarındaki bu hastalık çok kısa süre içerisinde çoğalıp yaprağın kuruyarak ölmesine ve bitkinin kök yerine tekrardan yaprağa yönelerek veriminin düşmesine sebep olmaktadır ("Şeker pancarında Cercospora yaprak lekesi hastalığı (Cercospora beticola sacc.)," 2016).



Şekil 2.2. Cercospora Beticola'nın yaşam döngüsü (Esmer, 2009).

Cercospora yaprak lekesi hastalığı görüntü olarak 4 farklı şekilde oluşan leke yapısına sahiptir. Hastalık belirtisi olan lekelerin ortak yanları gri veya kahverengi dış kenarlara sahip içe doğru halkalı bir yapıda olmalarıdır (Özgür, 2003).

2.1.2. Külleme hastalığı

Şeker pancarı yaprağı külleme hastalığı yaz mevsiminin kurak ve sıcak geçtiği şeker pancarı yetiştirilen bölgelerde oluşan bir hastalıktır. Külleme hastalığı, cercospora yaprak lekesi hastalığından sonra ülkemizde şeker pancarını etkileyen en önemli ikinci hastalıktır. Doğu Anadolu Bölgesi hariç diğer pancar üretimi yapılan yerlerde sıklıkla görülür. Külleme hastalığının ekim alanlarında ortaya çıkması ile ürün toplama zamanı arasındaki süre arttıkça elde edilecek ürün verimindeki azalmada aynı şekilde artmaktadır. Külleme hastalığı ilk olarak tarlanın farklı bölgelerinde ortaya çıkar ve kısa zaman içerisinde tarladaki bitkilerin geneline yayılır. Hastalığın erken başladığı durumlarda külleme hastalığının etkisinden bitki yaprakları zaman içerisinde ölürler. Şeker pancarı yapraklarının üstünde yer alan beyaz renkli unumsu tabaka ile belirtilerini gösterir (Resim 2.4) (Kaynaş, 2024).



Resim 2.4. Şeker pancarı külleme hastalığı

Şeker pancarı külleme hastalığı ile mücadele için başvurulabilecek başlıca yöntemler; ekim yapılacak alandaki bitki atıklarının temizlenip imha edilmesi, Külleme hastalığına karşı dirençli olan türlerin ekilmesi, sulama işleminin yağmurlama olarak yapılmasıyla yaprakların temizlenmesi, yabancı ot vb. gelişimlere tarlada izin verilmemesi olarak sıralanabilir (Kaynaş, 2024).

3. KURAMSAL TEMELLER


Çalışmanın bu bölümünde yapay zekâ, yapay sinir ağları, derin öğrenme, makine öğrenmesi, görüntü işleme ve evrişimli sinir ağları hakkında bilgi verilecektir.

3.1. Yapay Zekâ

Yapay zekâ; bilgisayar veya makineler insan zekâsının sahip olduğu gerçekleşen bir olaydan anlam çıkarma, daha önceki yaşanmışlıklardan öğrenme, akıl ve mantık yürütme gibi kabiliyetleri kazandırabilmektir (Yılmaz, 2021). Amaç insanlara ait olan düşünme, mukayese etme, öğrenme ve beyin işlevlerini modellemeye çalışmaktır, burada yapılan bilgisayarlar sayesinde insan zekâsının taklidi ve öğrenme yeteneğinin kazanılmasıdır (Serhatlıoğlu ve Hardalaç, 2009).

Yapay zekâyı iki temel yapı üzerinde inceleyebiliriz. Bunlar; insan gibi düşünme aşamalarının incelenmesi ve bu aşamaların makineler vasıtasıyla gösterilmesidir. Makineleri daha akıllı ve daha faydalı hale getirebilmek ve zekânın ne olduğunu anlayabilmek yapay zekânın hedefidir. Akıllı makinelerden beklenen davranışlar; tecrübeler ile öğrenme ve anlama, ilk defa karşılaşılan durumlara hızlı çözüm ve uyum sağlama, karışık verilerden anlam çıkarma, mukayese, öngörü ve karar verme kabiliyetidir (Yılmaz, 2021).


Yapay zekâyı ortaya çıkaran ve dizayn eden insan zekâsıdır. Geliştirilen yapay zekâ uygulamaları bulundukları ortamı ve kendisine verilen bilgileri yorumlayarak kendisinden beklenen ve amaçlanan sonuçlar için performansı yüksek seviyelere ulaştırmaktır. Yapay zekânın geçmişten günümüze kadar olan gelişim süreci Şekil 3.1’de gösterilmiştir. Yapay zekâ yapılacak işlemlerden oluşabilecek hataları en aza indirmeye, değerlendirmeye alınacak olan bilgiler ışığında oluşacak sonuçların daha verimli olmasına yardımcı olmaktadır (Sargın ve Göçen, 2023).



Şekil 3.1. Yapay zekâ gelişim süreci

3.2. Makine Öğrenmesi

Makine öğrenmesi, toplanan bilgileri temel alarak bunların ışığında sonuçlar üretmek amacıyla çeşitli algoritmalar oluşturan ve insanların öğrenme kabiliyetine benzer yapı geliştirmeye çalışan bir yapay zekâ teknolojisidir. Geleneksel programlamada program yazılır ve veri girişi yapılarak bilgisayarda çalıştırılır ve sonuç alınır. Makine öğrenmesinde ise sisteme veri girişi ve program çıktısı verilir, eğitim gerçekleşir ve test sırasında sonuca ulaşabileceği mantığı veya programı oluşturur (Şekil 3.2). Makineler öğrenme işlemini gerçekleştirirken veriyi eğitim ve test olmak üzere iki parçaya ayırarak çalıştırır. Eğitim için ayrılmış olan veri setini öğrenme işlemini gerçekleştirirken farklı algoritmalarda kullanarak kendini eğitir ve bunun sonucunda eğitimin başarılı olup olmadığını görmek içinse test veri seti ile öğrendiklerini test eder (Özgür, 2022).



Şekil 3.2. Makine öğrenmesi genel yapısı (İstanbulu, 2022)

Makine öğrenmesinde kullanılan algoritmalar kendilerine verilen sorunları doğru şekilde çözüme ulaştırabilmek için daha önceden benzer veri setleri ile eğitim görmesi gereken sistemlerdir. Veri setlerinin çözüme ulaştırabilecek şekilde düzgün hazırlanması ve yeterli sayıda veri bulunması eğitimin başarılı olabilmesi için yüksek öneme sahiptir.

Makine öğrenmesi ile amaçlanan en az insan müdahalesi ile maksimum seviyede daha çabuk ve genele hitap edebilen sonuçlar için öğrenme işleminin gerçekleşmesidir. Veriye dayanan herhangi bir model ya da nasıl yapılabileceği kurallar dâhilinde ifade edilen görevler makine öğrenmesi yardımıyla otomatikleştirilebilir.


Makine öğrenme süreci öğrenme işlemini gerçekleştirebilmek için çözülecek olan problemin belirlenmesi, çözümde kullanılabilecek veri setlerinin toplanması, problemin çözümüne en uygun olan algoritmanın seçimi, toplanan veri setlerinin eğitim, test ve doğrulama olmak üzere gruplara ayrılması, öğrenme işleminden sonra sonucun farklı veriler ile değerlendirilmesi ve sonucu en doğru şekilde ortaya çıkarabilecek parametrelerin ayarlanması olarak genellenebilir (İstanbulu, 2022).

3.3. Yapay Sinir Ağları

Bilgisayarlar tarafından insan beyninin en önemli fonksiyonu olan öğrenme işleminin gerçekleştirildiği sistemlerdir. Öğrenme gerçekleşirken benzer olaylardan faydalanılır. Yapay sinir ağlarında girilen veriler farklı toplama ve sonuç üretme fonksiyonlarından

geçirilerek sonuç üretilerek ağ içerisindeki diğer işlem elemanlarına gönderilir. Ağ içerisindeki her bir bağlantının bir ağırlık değeri vardır. Girilen verilerden doğru sonuçları alabilmek için ağırlık değerlerinin doğru olması gerekmektedir. Doğru ağırlık değerlerinin bulunabilmesi içinde ağı eğitilmesi gerekmektedir. Eğitim için ağa gösterilen örnekler üzerinden öğrenme işlemi gerçekleştirilir. Öğrenme işlemi eğitim için ayrılan eğitim veri setindeki örnekler için doğru sonuçlar üretilene kadar devam eder. Doğru sonuçlar elde edildikten sonra ağ eğitilmiş olarak kabul edilir (Öztemel, 2003).

Yapay sinir ağlarını ortaya çıkaran model öğrenme işlemlerini matematik tabanlı olarak modellemektir. Modelin gelişiminde biyolojik sinir ağları temel alınarak bilgisayarların veriler üzerinde işlem yapma ve öğrenme kabiliyetlerini geliştirme vardır (Kabalcı, 2024).



Şekil 3.3. Yapay sinir ağlarının genel yapısı (Sargın ve Göçen, 2023)

Yapay zekânın bir alt modeli olan yapay sinir ağları insan beyninin gerçekleştirdiği öğrenme işlemlerinin benzerini yaparak bilgisayarlara çözümü zor olan durumlarda sonuç üretme kabiliyeti edindirmek için geliştirilmiştir. Yapay sinir ağlarının yapısında birden fazla katman bulunmaktadır bu katmanlarda bulunun yapılar sayesinde bu sistemler insan beynindeki sinir hücreleri gibi veriler üzerinde işlem yapma kabiliyetine sahiptirler (Öztürk ve Şahin, 2018).

3.3.1. Yapay sinir ağlarının yapısı

Yapay sinir ağlarının genel yapısı Şekil 3-3'de gösterilmiştir. Giriş katmanı, ara katman (gizli katman) ve çıkış katmanı olmak üzere üç katmanlı bir mimari olarak ele alınabilir.

Giriş katmanı; bu katman yapay sinir ağına eğitim için kullanılacak olan verilerin geldiği katmandır. Bu katmanda genellikle hiçbir işlem yapılmadan girdiler sonraki katmanlara yönlendirilirler.

Ara katmanlar; giriş katmanından gelen verilerin üzerinde işlemlerin ve öğrenmenin yapıldığı katmandır. Kullanılacak sisteme göre bir veya daha fazla ara katman olabilir. Ara katman sayısının artması ile beraber sistemde yer alan hücre sayısı yapılacak eğitim ve hesaplama süresini uzatsa da kompleks yapıya sahip problemlerin çözümünde ağın kullanılmasına olanak sağlar.

Çıkış katmanı; ağı girilen verilere göre çıktılarının olduğu katmandır. Üretilen sonuçlarda eğitimde kullanılan veri setine bağlı olarak sınıf bilgileri veya etiket değerleri yer alır.

3.3.2. Yapay sinir ağı sınıflandırılması

Yapay sinir ağlarını temel olarak katmanlarına göre, yapılarına göre ve öğrenme yöntemlerine göre olmak üzere 3 ana sınıfa ayırabiliriz (Büşra, 2022).

Katmanlarına göre yapay sinir ağları tek katmanlı ve çok katmanlı olmak üzere ikiye ayrılır. Tek katmanlı yapay sinir ağlarında giriş ve çıkış katmanları yer alır. Karışık ve doğrusal olmayan sorunların çözümde yetersiz kalmıştır (Öztemel, 2003). Çok katmanlı yapay sinir ağlarında, tek katmanlı yapay sinir ağlarından farklı olarak bir ya da daha fazla katmana sahip olan ara katman yer alır. Her katmanda yer alan hücreler diğer katmandaki hücreler ile bağlantılıdır (Ataseven, 2013).

Yapılarına göre yapay sinir ağlarını da ileri yönlü besleme ve geri beslemeli olarak ikiye ayırabiliriz. İleri beslemeli yapay sinir ağlarında sistemin üzerinde verinin iletilmesi tek yönlü olarak giriş katmanından, çıkış katmanına doğru olmaktadır (Katırcıoğlu, 2019). Geri beslemeli yapay sinir ağlarında veri akış yönü sadece ileriye doğru değildir ters yönde de


olabilir. Giriş katmanından gelen veri ara katmana veya gizli katmandan giriş katmanına doğru olabilir. Besleme işlemi iki yönlü olduğundan dolayı oluşabilecek hataların azalması sağlanır (Çoban, 2019).

Öğrenme yöntemine göre yapay sinir ağlarında danışmalı ve danışmansız öğrenme olmak üzere iki yapı vardır. Genellikle tercih edilen danışmalı öğrenmedir. Bu yöntemde ağa giriş ve çıkış verileri verilerek eğitim sonunda verilen çıkış değerinin üretilmesi istenir. Üretilen sonuç ile verilen sonuç arasındaki fark karşılaştırılarak oluşan hata seviyesi istenilen seviyeye gelene kadar eğitim işlemi tekrarlanır (Yanık, 2019).

3.4. Derin Öğrenme

Derin öğrenme, birden çok katmanın oluşturmuş olduğu makine öğrenme dalıdır, yapılan işlem sonuç üretmek için eğitimde veri setlerini kullanmaktır. Önceki maddelerde bahsedilen yapay zekâ, makine öğrenmesi ve derin öğrenme anlam ve işleyiş bakımından birbirinden farklı olan yapılardır. Bu yapılarda en üstte yapay zekâ sonra sırasıyla makine öğrenmesi ve derin öğrenme gelmektedir (Sargın ve Göçen, 2023).

Derin öğrenme algoritmaları da öğrenme işlemini gerçekleştirebilmek için veriye ihtiyaç duyar bu yönüyle de derin öğrenme için makine öğrenmesinin alt dalı olarak da tanımlayabiliriz. Makine öğrenimi ve derin öğrenme sistemlerinin birbirinden ayırt edici özellikleri bulunmaktadır (Şekil 3.4). Derin öğrenmede yer alan algoritmaların içinde yer alan çok katmanlı bir yapı mevcuttur (Oppermann, 2023).



Şekil 3.4. Makine öğrenmesi ve derin öğrenme (Sargın ve Göçen, 2023).


Derin öğrenme ile eğitim setinde kullanılan verilerin nitelikleri arasında olan karmaşık bağlantılar öğrenilebilir, eğitim işlemi için büyük veri setlerine olanak vermesi öğrenme işleminin daha başarılı yapılmasına ve bunun sonucunda da doğru tahminler üretilmesine olanak sağlar. Derin öğrenme modellerini eğitebilmek için minimum düzeyde kullanıcı müdahalesine ihtiyaç duyar, öğrenme işlemi için gerekli olan veriler kullanılan sistemlere bağlı olarak sosyal medya ya da kullanılan algılayıcılar sayesinde elde edilerek eğitim işleminin sürekli ve büyük veriler üzerinden yapılmasına olanak sağlar (Cloud).

3.5. Evrişimli/Konvolüsyonel Sinir Ağları (Convolutional Neural Networks –(CNN))

Evrişimli sinir ağları görüntüler üzerinde sınıflandırma, nesne tanıma ve görüntü işleme sorunlarının çözümünde kullanılan bir derin öğrenme algoritmasıdır. Kendisine verilen resim veya videolardaki nesnelere ağırlık değerleri atayarak bunların ayırt edilmesini sağlayan bu işlemi yaparken nesneler arasındaki ilişkileri de tespit edebilen bir yapıya sahiptir (Şekil 3.5.) (Koç, 2022).


Giriş olarak sunulan verilerin bilgisayarlar tarafından algılanabilmesi için piksel değerlerinden oluşan bir matris yapısına çevrilmesi gerekmektedir. Sayısal formata çevrilen görüntüler üzerindeki her bir ayrıntı bu sayede ayırt edilebilir hale dönüştürülür. Görüntülerin ayırt edilmesini sağlayanda bu yapıdır. Farklı değerlere sahip olan matris

değerlerinin sahip olduğu etiketler eğitim sırasında öğrenilerek sonraki görüntüler üzerinde tahmin yapılması sağlanır (Akdoğan, 2020).




Şekil 3.5. Örnek evrişimli sinir ağı (Ergin, 2018).

CNN'ler nesne tespiti yaparken görüntüleri ayrılmış olan matrisler üzerinden parça parça yapar. Karşılaştırılan ve aranan her parça bir özelliği içerir ve aynı konumdaki ya da benzer yapıdaki eşleşen bu özellikler sayesinde görüntü tespiti işlemi gerçekleştirilir bu işlemle ilgili basit bir örnek Şekil 3.6. ve Şekil 3.7. 'de gösterilmiştir.



Şekil 3.6. CNN çalışma örneği 1 (Rohrer, 2016).




Şekil 3.7. CNN çalışma örneği 2 (Rohrer, 2016).

CNN yapısında görüntü verileri piksel olarak çıkarıldıktan sonra bu bilgiler üzerinden sınıflandırma ve özellik belirleme işlemi gerçekleştirilir. Burada yapılan işlem esasında piksel bilgilerinin karşılaştırılması olarak gözükse de yapılan aslında bu bilgiler arasındaki yani görüntülerde yer alan çizgi, köşe veya şekil tabanlı özellik çıkarımıdır. CNN'ler iki temel bölümden oluşur bunlardan ilki verilerden özellik çıkarımı yapıp bunların karşılaştırıldığı evrişim ve havuzlama katmanı, diğeri ise bu katmanlardan gelen veriyi tahmin eden tam bağlantılı katmandır (Koç, 2022).

3.5.1. Evrişim katmanı


CNN'in temelini oluşturan katmandır. Bu katmanda verilen görüntünün piksel matrisi üzerinde bir filtre matrisi ile sol üst köşeden başlayarak öznitelik çıkarma işlemi için hesaplama yapılır (Şekil 3.8). Yapılan bu hesaplamalar sonucunda eğitim ve sonuç üretme işlemlerinde ağırlığı olan yani görüntüler üzerindeki farklılıkları çıkartacak olan öznitelikler kullanılır. Görüntüler üzerinde fark olmayan özniteliğe sahip alanlar işleme sokulmazlar (Akdoğan, 2020).



Şekil 3.8. Öznitelik hesaplama işlemi (Akdoğan, 2020).

3.5.2. Havuzlama katmanı


Evrişim katmanında gerçekleşen hesaplamalar sonucunda elde edilen özellik haritasının boyutunun azaltıldığı ve üretilen özniteliklerin belirginleştiği katmandır. Filtreleme işleminden sonra elde edilen matris üzerinde en büyük ve ortalama havuzlama olmak üzere iki türü vardır. En büyük havuzlamada filtreye göre en yüksek değerler alınırken, ortalama havuzlamada değerlerin ortalaması alınır (Yavuz, 2021).



Şekil 3.9. En büyük ve ortalama havuzlama işlemi (Koç, 2022).

3.5.3. Tam bağlı katman

Havuzlama katmanından sonra gelen tam bağlı katman eğitim işleminden geçen verileri sınıflandırma işlemi ile ayrıştırır (Şekil 3.10). Sonuç olarak üretilecek sınıfın özelliklerine göre tahmin işlemi gerçekleştirilir. Elde edilecek sonuç ile sınıf sayısı aynıdır.




Şekil 3.10. Tam bağlı katman yapısı (Karacan, 2024).

3.6. Nesne Algılama Modelleri

3.6.1. R-CNN


R-CNN (Region Based Convolutional Neural Networks) algoritması görüntülerden nesneleri tespit etmek için seçilen bir bölge içerisinde nesnenin olup olmadığı kontrol edilir. Bölgeleri tanımlama işlemi yapılırken bölgeyi temsil eden değişkenler, renk, doku ve çevre bilgileri kullanılır. Bu bölge tespit edildikten sonra CNN içinde eğitime tabi tutulur. Eğitim için verilen her veride 2000 bölge çıkarılır ve ayrı ayrı CNN üzerinde eğitim işlemine alınır bu işlem hem sistemin yavaşlamasına hem de yapılan eğitim işleminin uzun sürmesine neden olur. R-CNN yapısı Şekil 3-11’de gösterilmiştir (Meşeci, 2021).



Şekil 3.11. R-CNN algoritma yapısı.

3.6.2. Fast R-CNN

Fast R-CNN modeli R-CNN modeli gibi her bir görüntü başına CNN'leri 2000 defa çalıştırmaz, her görüntü için bir defa çalıştırılır ve nesneleri barındıran bölgeler tespit edilir. Fast R-CNN çalışma mantığı sırası ile tüm görüntü CNN üzerinde eğitime tabi tutulur, bunun sonunda özellik haritası elde edilir. Özellik haritası üzerinde bölge tespit işlemi yapılır, havuzlama katmanı ile boyutlandırma ve son olarak da sınıflandırma işlemi gerçekleşir (Şekil 3.12).




Şekil 3.12. Fast R-CNN mimarisi (Girshick, 2015).

3.6.3. Faster R-CNN

R-CNN ve Fast R-CNN modellerini yavaşlatan en büyük nedenlerden biri her görüntü için 2000 bölge oluşturmaları ve her iki modelinde seçici arama yöntemini kullanmasıdır. Fast R-CNN ile bölge sorunu ortadan kalksa da seçici arama bağıllığı devam etmektedir. Seçici arama algoritması yerine kullanılabilecek bir algoritma geliştirildi (Ren, He, Girshick, ve Sun, 2015). Faster R-CNN özellik haritasının üzerinden bölgeleri seçmek için RPN (Region Proposal Network – Bölge Teklif Ağı) kullanır.

Eğitime alınacak görüntü CNN üzerinde eğitime tabi tutulur, bölge teklif ağı hangi bölgelerin seçileceği nesnelere ait olan değerler ile geri döndürülür; gelen değerlere ait olan bölgeler tahmin işleminin yapılabilmesi için ROI havuzlama katmanı ile boyutu küçültülür

ve son olarak tam bağılı katmana iletilerek sınıflandırma tahmin kutuları oluşturulur (Meşeci, 2021). Şekil 3.13. 'de Faster R-CNN mimarisi görülmektedir.




Şekil 3.13. Faster R-CNN mimarisi (Meşeci, 2021)

3.6.4. Mask R-CNN

Mask R-CNN modelinde Faster R-CNN'de üretilen sınıflandırma etiketi ve nesnenin sınırlarını belirleyen kutu adresine ilave olarak tespit edilen nesnenin maskesini işaret eden bir yapı daha eklenir (Özdemir, 2021).

Mask R-CNN üç bölümden meydana gelir bunlar bölge teklif ağı (RPN- Region Proposal Network), ağ üzerinden hesaplanan ve nesnelerin bulunma olasılıklarının olduğu ilgi bölgeleri katmanı ROI (Region of Interest) ve üçüncü bölümde ise sonuçların üretildiği tam


bağlı katmanlar. Mask R-CNN verilen görüntü içindeki nesneleri aynı anda tespit etme ve bu noktalar üzerinde segmentasyon maskesi oluşturma işlemini başarılı bir şekilde gerçekleştirir (Karatepe, 2023). Şekil 3.14. 'de modelin genel yapısı gösterilmiştir.



Şekil 3.14. Mask R-CNN genel mimarisi (Gonzalez, Arellano, ve Tapia, 2019)

3.6.5. SSD (Single shot multibox detector)

R-CNN modelleri nesne tespiti işleminde ne kadar başarılı olsa da gerçek zamanlı nesne tespitinde de sistemin yavaş olmasından dolayı istenen verimi verememektedir. Nesne tanıma işlemleri için kullanılan bölge öneri ağı ve nesneleri sınıflandırma işlemini göstermek için uygulanan sınırlayıcı kutu oluşturma işlemi saniyede 7 kare üzerinde gerçekleştirilir. Saniyede 7 kare üzerinde işlem yapılması gerçek zamanlı nesne tespiti işlemleri için yetersiz bir sayıdır bu değeri arttırmak ve sistemi hızlandırmak için SSD bölge öneri ağını model içerisinden kaldırmaktadır. Bölge öneri ağının kaldırılmasıyla oluşabilecek tahmin doğruluğu düşüşünü azaltmak için sistemde iyileştirmeler yapılmıştır (Ergene, 2019). Modelin yapısı Şekil 3.15. 'de gösterilmiştir.



Şekil 3.15. Single shot multibox detector (SSD) mimarisi (Başarır, 2019)

3.6.6. ResNet (Residual Network)

Derin sinir ağlarında ortaya çıkan eğitim zorluk ve kayıplarını en aza indirmek için geliştirilmiş bir mimaridir. ResNet artık bağlantılar olarak bilinen ve ardışık katmanın çıkışı yerine girişini sonraki katmanın çıkışına ekleyen bir yapıya sahiptir. Bu yapı sayesinde ağın daha derin olması sağlanır. Ağın derinleşirken öğrenme yerine ezberleme yapmasını engellemek ve öğrenme limitlerini yükseltmek için identity mapping kullanır. ResNet sahip olduğu katman sayısına göre farklı modellerde isimlendirilmektedir. Önceden eğitilmiş olan ResNet modelleri yeni eğitimler de daha başarılı başlangıç değerleri verirler. ResNet günümüzde görüntü sınıflandırma, nesne tanıma, segmentasyon, video analizi gibi farklı alanlarda kullanılmaktadır (Püsküllü, 2023).


3.6.7. DenseNet (Dense Convolutional Network)

DenseNet yoğun bağlantılı evrişim ağı, katmanları kendisinden sonra gelen katmanlara ileriye doğru bağlamaktadır. ResNet yapısına benzer özelliklere sahiptir. İki ağ arasındaki temel fark DenseNet'in kendisinden önceki katmanlardan gelen çıktıları birleştirmesidir. Her katman kendisinden önceki katmanların özelliklerini giriş olarak alıp, kendi özellikleri ile elde ettiği sonucu sonraki katmanlara iletmektedir. Bu yapı sayesinde özellik yayılımını gerçekleştirerek sonradan kullanılacak olan parametre sayısının azalmasını sağlamaktadır (Şener ve Ergen, 2022).

3.6.8. YOLO (You Only Look Once)

Günümüzdeki nesne tanıma modellerinden en popüler olanlarının arasında olan YOLO Joseph Redmon ve arkadaşlarının Washington Üniversitesinde yayınladıkları “You only look once: Unified, real-time object detection” isimli makale ile tanıtıldı (Redmon, Divvala, Girshick, ve Farhadi, 2016). YOLO’yu geliştiren ekipte yer alan Ross Girshick aynı zamanda Faster R-CNN modeli içinde çalışmalarda bulunuyordu. Her iki modelde de özellik haritasını oluşturmak için CNN katmanlarının kullanılması bu modeller arasında benzer yapılar olduğunu göstermektedir. Bununla birlikte Faster R-CNN iki aşamalı görüntü tespit algoritması kullanılırken YOLO’da ayrı bir katman olmadığı için daha hızlıdır.

YOLO (You only look once) isminden de anlaşılacağı üzere üzerinde işlem yapılacak görüntüye bir kere bakar ve nesne tespit işlemini gerçekleştirir. YOLO verilen görüntü üzerinde nesnelerin bulunma ihtimali ve görüntülerin çerçevesini belirleyen sınırlayıcı kutuları tespit edebilmek için ızgaralara bölme işlemini gerçekleştirir. Bu işlemle beraber nesne ve sınırlayıcı kutu koordinatları tespit edilirken nesnenin sınıfı da tespit edilmiş olur. Tüm bu işlemler YOLO çalışma mantığına bağlı olarak tek geçişle ve ileri yönlü olarak yapıldığı için R-CNN modellerine göre hızlı ve doğru sonuçlar üretilmesini sağlar (Mirkhan, 2023).




Şekil 3.16 YOLO ve diğer modellerin hız karşılaştırılması

Gerçek zamanlı görüntü tespit algoritmaları içerisinde YOLO diğer rakiplerine göre işlemleri sonuçlandırma hızı, tespit edilen nesnelerin doğruluk oranı, elde edilen sonuçların genel yayılması ve açık kaynaklı bir yapıya sahip olduğu için daha fazla tercih edilmektedir (Keita, 2022). YOLO ve diğer görüntü algılama algoritmalarının hız bakımından karşılaştırılmasına ait grafik Şekil 3.16 'da gösterilmiştir.

YOLO nesne tespit işlemini gerçekleştirirken aşağıdaki adımları takip eder (Mirkhan, 2023):


1. Üzerinde nesne tespiti yapılacak olan görüntü özellik haritasının çıkarılması için YSA üzerinden geçirilir.
2. Çıkarılan özellik haritalarına bağlı olarak sınıf ve nesnenin bulunduğu yeri temsil eden sınırlayıcı kutu koordinatlarının tahmin edileceği tam bağlı katmandan geçirilir.
3. Görüntü ızgara halinde hücrelere ayrılmış ve her hücre için içinde nesne olup olmadığı bilgisi ve kutu koordinatları tespit etme işlemini yapar.
4. Yapılan tespite göre hücreler için sınıf ve sınırlayıcı kutu bilgileri elde edilir.
5. Aynı nesneyi işaret eden sınırlayıcı kutulardan içinde nesne bulunma olasılığı en yüksek olan hariç diğerlerini kaldırma işleminin yapıldığı bir filtre uygulanır.
6. Sonuç olarak tespit edilen nesneler için sınırlayıcı kutu ve sınıf bilgilerini içeren bir dizi üretilir.

Yapılan bu işlemler YOLO'nun temel yapısını ifade etmektedir ve Şekil 3.17.'da gösterilmiştir.



Şekil 3.17. YOLO algoritmasının çalışma mantığı (Tekin, 2019).


Şekil 3.18.'de gösterildiği gibi YOLO temel mimarisinde 24 evrişimli katman, dört maksimum havuzlama katmanı ve iki tane tam bağlı katman bulunmaktadır.



Şekil 3.18. YOLO temel mimarisi (Keita, 2022).

YOLO duyurulduğu 2015 yılından günümüze kadar sürekli gelişim göstermiş ve yeni versiyonları çıkmıştır. YOLO geliştiricisi ilk yazar Joseph Redmon YOLOv3'den sonra bu alanda çalıştırmayı durdurmuş olsa da YOLO'nun sağlamış olduğu hız ve esneklik başka

yazarlar tarafından geliştirilmeye devam etmiş ve en son (2024) YOLOv9 geliştirilmiştir. Şekil 3.19.'de 2015'den 2024'e kadar olan YOLO versiyonlarının gelişimi gösterilmiştir.




Şekil 3.19. YOLO sürümlerinin gelişimi

YOLOv3 ve daha sonra geliştirilen sürümlerinin sağlamış olduğu yenilikler ve göstermiş olduğu yüksek hız ve doğruluk oranı ile YOLO günümüzde birçok firma tarafından kullanılmaktadır. Nvidia firması üretmiş olduğu ekran kartları ile YOLO uygulamalarını kullanarak daha verimli çalışmasını sağladı. Görüntü tespitinde oldukça başarılı sonuçlar üreten YOLO sürümleri için birçok firma etiketleme araçlarını geliştirerek kullanıma açmıştır. Görüntü tespit ve takip uygulamalarında YOLO'yu kullanan diğer bir firmada Microsofttur. Gerçek zamanlı görüntü tespitinin en yaygın kullanıldığı cihazlardan olan drone üretici firmalarda YOLO'yu tercih etmektedir (Kuru, 2023).

4. MATERYAL VE YÖNTEM

4.1. Nesne Sınıflandırma ve Nesne Tespiti

Görüntüler üzerinde en yaygın olarak kullanılan iki işlem görüntü sınıflandırma ve nesne tespit işlemidir. Görüntü sınıflandırma bilgisayarlı görü işleminin en temel halidir. Tüm görüntü üzerine etiket ya da sınıf ataması yapılarak eğitim işlemi gerçekleşir. Temel olarak görüntüde ne olduğunu bulmayı amaçlar, verilen görüntü üzerinden yaprağın hangi hastalığa ait olduğunu ya da hasta olup olmadığı gibi temel sorulara cevap verir. Nesne tespiti ise verilen görüntü üzerindeki nesneleri ve konumlarını belirleyen bir yapıya sahiptir. Görüntü işleminden geçtikten sonra sonuç olarak tespit edilen nesnelerin bulunduğu konumlar ve sınıf bilgileri ile sonuçlar üretilir. Görüntü sınıflandırmada sonuç tek bir sınıf bilgisi olurken nesne tespitinde birden fazla sınıf bilgisi ve tespit edilen sınıfları içine alan sınırlayıcı kutular bulunur. Nesne tespit ve sınıflandırma işlemine ait örnek görüntü Resim 4.1.' de gösterilmiştir.



Resim 4.1 Nesne sınıflandırma ve nesne tespiti

4.2. Veri Setinin Oluşturulması

Tez çalışmasında pancar bitki hastalıklarının tespiti ve sınıflandırılması için kullanılacak olan fotoğraflar Amasya ili Suluova ilçesi Değirmendere bölgesindeki pancar ekimi yapılan bölgelerden elde edilmiştir. Fotoğraf çekiminde akıllı telefon kullanılarak 2 252 x 4 000 piksel çözünürlükte 200 adet görüntü elde edilmiştir. Çekilen fotoğraflar bilgisayar ortamına aktararak sağlıklı, Cercospora (yaprak lekesi) ve Powdery Mildew (külleme hastalığı) olarak sınıflara ayrılmıştır. YOLO ile yapılacak sınıflandırma işlemi için fotoğraf sayısı veri arttırma yöntemleri (döndürme, gürültü ekleme) kullanılarak yükseltilmiştir. Tüm bu işlemler sonucunda sınıflandırma için oluşan görüntü sayısı ve ait oldukları sınıfları belirten tablo çizelge 4.1. 'de, klasör yapısı Şekil 4.1. 'de ve veri setinden örnek bir görüntüde Resim 4.2. 'de gösterilmiştir.

Çizelge 4.1. Sınıflandırma işlemi için kullanılan görüntü sayıları


Sınıf – Hastalık	Toplam Görüntü	Eğitim	Test
Cr (Cercospora)	748	628	120
Pm (Powdery Mildew)	212	164	48
He (Sağlıklı)	531	470	61
Toplam	1491	1262	229

```

Data/
|
| - train/
| | - cr/
| | | - cr0001.jpg
| | | - cr0002.jpg
| | | - ...
| |
| | - pm/
| | | - pm0001.jpg
| | | - pm0001.jpg
| | | - ...
| |
| | - he/
| | | - he0001.jpg
| | | - he0001.jpg
| | | - ...
|
| - test/
| | - cr/
| | | - cr0001.jpg
| | | - cr0002.jpg
| | | - ...
| |
| | - pm/
| | | - pm0001.jpg
| | | - pm0001.jpg
| | | - ...
| |
| | - he/
| | | - he0001.jpg
| | | - he0001.jpg
| | | - ...
|


```

Şekil 4.1. Sınıflandırma işlemi klasör yapısı



Resim 4.2. Sınıflandırma işlemi için kullanılan veri setinden görüntü

YOLOv8 modelinin şeker pancarı bitkisinin hastalıklı alanlarının tespiti ve hastalıklı yaprakların sınıflandırması Şekil 4.2.' de gösterilmiştir.




Şekil 4.2 Şeker pancarı yaprak hastalıkları tespiti akış şeması

4.3. Kullanılan Yazılımlar ve Kütüphaneler


Tez çalışmamda pancar bitki yapraklarındaki hastalıkların sınıflandırılması için YOLOv8, ResNet ve DenseNet derin öğrenme modelleri kullanılmıştır. Modellerin eğitimi için ücretsiz olarak GPU ve CPU kullanımına imkân sağlayan Google Colab kullanılmıştır. Yapılacak olan eğitimlerin daha verimli ve kısa zamanda tamamlanabilmesi için Colab üzerinde GPU Nvidia Tesla A100 modeli seçilmiş ve kullanılmıştır. 2023 yılının başlarında kullanıma sunulan YOLOv8 modeli Ultralytics firması tarafından geliştirilmiş ve YOLOv5 modelini temel alan bir mimari üzerine kurulmuştur. YOLOv8'e eklenen eğitim sonuçlarını iyileştirmeye yönelik düzenlemeler ve yapılan iyileştirmeler ile görüntü tespiti,

sınıflandırılması ve segmentasyonu işlemleri için en çok kullanılan modellerin başında gelmektedir (Kaya ve Çodur, 2023). YOLOv8 genel yapısı Şekil 4.3.' de gösterilmiştir.



Şekil 4.3 YOLOv8 genel mimarisi (Herfandi, Sitanggang, Nasution, Nguyen, ve Jang, 2024).

YOLOv8 nesne tespiti yaparken işlenecek görüntüyü ızgara şeklinde parçalara ayırır, daha sonra her ızgara kutusuna nesneleri tahmin etmekle görevli tahmin kutuları eklenir.



Şekil 4.4. YOLO nesne tespit işlemi

Eklenen kutular daha sonra içinde nesne olma olasılığına göre ağırlık değeri alırlar ve en yüksek değere sahip olan kutunun nesneyi tespit etme oranıyla görüntülenir. İşleme ait ekran görüntüleri Şekil 4.4.' de gösterilmiştir.

Hiperparametre ayarları

Hiperparametre ayarlama işlemi modelin eğitim parametrelerinden en uygun sonuçları verecek olan değerleri seçmek ya da bulmak için yapılan işlemdir. YOLO'da en yaygın olarak kullanılan hiperparametrelerden bazıları, öğrenme oranı(lr0), batch büyüklüğü, epoch sayısı ve değiştirilebilir olan diğer mimari özelliklerdir. YOLO üzerinden hiperparametre ayarları yapmak için model.tune fonksiyonu kullanılır ve bu fonksiyon sonuç olarak modelin eğitiminde kullanılabilecek en uygun değerleri içeren bir ayar dosyası verir (best_hyperparameters.yaml) bu dosya içerisinde eğitim işleminde kullanılacak olan default parametrelerin yerine sistem tarafından seçilmiş olan değerler yer alır. Eğitimde kullanılacak olan model için oluşturulan parametre dosyası içeriği Şekil 4.5'de gösterilmiştir.

```
lr0: 0.01
lrf: 0.01
momentum: 0.937
weight_decay: 0.0005
warmup_epochs: 3.0
warmup_momentum: 0.8
box: 7.5
cls: 0.5
dfl: 1.5
hsv_h: 0.015
hsv_s: 0.7
hsv_v: 0.4
degrees: 0.0
translate: 0.1
scale: 0.5
shear: 0.0
perspective: 0.0
flipud: 0.0
fliplr: 0.5
bgr: 0.0
mosaic: 1.0
mixup: 0.0
copy_paste: 0.0
```

Şekil 4.5 Hiperparametre dosyası içeriği

4.4. Performans Metrikleri

Eğitim sonunda oluşan modelin yapılan test sonucunda ne kadar başarılı olup olmadığını anlayabilmek yani performans değerlendirmesi yapmak için Karışıklık matrisi (Confusion matrix) kullanılır (Ruuska ve diğerleri, 2018). Karışıklık matrisi değerlendirilirken TP, TN, FP ve FN değerlerine göre sınıflandırma yapılır. TP True Positive (Doğru Pozitif), TN True Negative (Doğru Negatif), FP False Positive (Yanlış Pozitif), FN False Negative (Yanlış Negatif) olarak sınıflandırılır. Karışıklık matrisi Şekil 4.6. 'de gösterilmiştir.

		Gerçek Değer	
		Pozitif	Negatif
Tahmin Edilen Değer	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 4.6. Karışıklık matrisi (Confusion matrix)

Karışıklık matrisindeki sınıflandırmada kullanılan değerleri tezimizde değerlendirecek olan Cercospora ve Sağlıklı sınıfları üzerinden açıklayalım:

- True Positive (Doğru Pozitif): Cercospora sınıfında olarak tahmin edilen görüntünün Cercospora sınıfında olması.
- True Negative (Doğru Negatif): Cercospora sınıfında olmadığı tahmin edilen görüntünün Cercospora sınıfında olmamasıdır.
- False Positive (Doğru Negatif): Cercospora sınıfında olarak tahmin edilen görüntünün Sağlıklı sınıfında olması.
- False Negative (Doğru Pozitif): Cercospora sınıfında olmadığı tahmin edilen görüntünün Cercospora sınıfında olması.

Doğruluk, eğitim sonucunda üretilen modelin sınıflandırma işlemini doğru şekilde sonuçlandırma oranıdır ve denklem 1’de gösterilmiştir. Hassasiyet pozitif sonuç olarak tahmin edilen görüntülerin gerçekte de pozitif olma durumunu ifade eder ve denklem 2’de gösterilmiştir. Duyarlılık eğitim sonucunda üretilen modelin gerçek pozitifleri doğru tahmin etme oranıdır ve denklem 3’de gösterilmiştir. F1 skor hassasiyet ve duyarlılık değerlerinin harmonik olarak ortalaması olarak ifade edilebilir ve denklem 4’de gösterilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP + FP + TN + FN} \quad (1)$$

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = \frac{2*TP}{2*TP+FP+FN} \quad (4)$$

5. DENEYSEL BULGULAR

Bu çalışma bünyesinde pancar bitki yapraklarındaki hastalıklarının derin öğrenme yöntemleriyle sınıflandırılması amacıyla YOLOv8 modelinin YOLOv8x-cls, YOLOv8l-cls ve YOLOv8m-cls alt modelleri, ResNet50 ve DenseNet121 transfer öğrenme yöntemleri ile yapılan eğitimler ve bu eğitimlerin sonuçları incelenmiştir. YOLOv8 geliştiricisi Ultralytics sitesindeki sınıflandırma dokümanlarında bu üç modelinde ImageNet veri seti üzerinde birbirine en yakın sonuçları elde ettiği Çizelge 5.1.' de görülmektedir.

Çizelge 5.1 YOLOv8 modellerinin ImageNet veriseti başarımları


Model	Size (pixels)	Acc top1	Acc top5	Speed CPU ONNX (ms)	Speed A100 TensorRT (ms)	Params(M)	FLOPs (B) at 640
YOLOv8n-cls	224	69,0	88,3	12,9	0,31	2,7	4,3
YOLOv8s-cls	224	73,8	91,7	23,4	0,35	6,4	13,5
YOLOv8m-cls	224	76,8	93,5	85,4	0,62	17,0	42,7
YOLOv8l-cls	224	76,8	63,5	163,0	0,87	37,5	99,7
YOLOv8x-cls	224	79,0	94,6	232,0	1,01	57,4	154,8

YOLOv8x-cls, YOLOv8l-cls ve YOLOv8m-cls modelleri için eğitimde kullanılacak görüntü boyutları 224x224 piksel olarak ayarlanmıştır. Eğitim işlemi Google Colab ortamında Tesla A100 GPU'ya sahip olan sunucu üzerinde yapılmıştır. Modellerin eğitiminde hiperparametre dosyasındaki değerler ve 3 model içinde 50 ve 100 epoch'luk ve 16, 32, 64 değerlerine sahip batch boyutu sırasıyla kullanılmıştır. 3 model ile yapılan eğitim sonuçlarında %97,82 accuracy oranı ile YOLOv8x-cls ve YOLOv8m-cls en yüksek değeri elde etmişlerdir. Modellere ait doğruluk değerlerini içeren tablo Çizelge 5.2.' de gösterilmektedir.

Çizelge 5.2. Eğitimde kullanılan modeller ve doğruluk-accuracy sonuçları

Model	Doğruluk- Accuracy
YOLOv8x-cls	0.9782
YOLOv8l-cls	0.9738
YOLOv8m-cls	0.9782
ResNet50	0.9339
DenseNet121	0.9444

YOLOv8x-cls, YOLOv8l-cls ve YOLOv8m-cls modellerine göre train/loss (eğitim/kayıp) grafikleri Şekil 5.1. 'de verilmiştir.



Şekil 5.1 YOLOv8x-cls, YOLOv8l-cls ve YOLOv8m-cls modellerine göre train/loss (eğitim/kayıp) değerleri


5.1. YOLOv8x-cls Modeli Sınıflandırma Sonuçları

YOLOv8x-cls modeli ile gerçekleştirilen eğitim sonucunda %97,82 oranında doğruluk değeri elde edilmiştir. Yapılan eğitim sonucunda külleme sınıfında en yüksek değer elde edilmiştir. Daha sonra sırasıyla sağlıklı ve yaprak lekesi sınıfları gelmiştir. Diğer sınıflara göre eğitim modelinin test sonuçları Çizelge 5.3.' de gösterilmiştir.

Çizelge 5.3 YOLOv8x-cls modeli eğitim sonuçları

Class Name	Precision	1-Precision	Recall	1-Recall	f1-score
Yaprak Lekesi	0,9667	0,0333	0,9915	0,0085	0,9789
Sağlıklı	0,9792	0,0208	0,9400	0,0600	0,9592
Külleme	1,0000	0,0000	0,9839	0,0161	0,9919

YOLOv8x-cls modelinin ortaya koyduğu sonuçlar için oluşturulan karışıklık matrisi Şekil 5.2.' de gösterilmiştir.



Şekil 5.2 YOLOv8x-cls karışıklık matrisleri


5.2. YOLOv8l-cls Modeli Sınıflandırma Sonuçları

YOLOv8l-cls modeli ile gerçekleştirilen eğitim sonucunda %97,38 oranında doğruluk değeri elde edilmiştir. Yapılan eğitim sonucunda YOLOv8x-cls modelinde olduğu gibi külleme sınıfında en yüksek değer elde edilmiştir. YOLOv8x-cls modeli ile elde edilen sonuçlardan farklı olarak yaprak lekesi sınıfı ikinci yüksek değere sahip olurken en düşük doğrulama değeri sağlıklı sınıfa aittir (Çizelge 5.4).

Çizelge 5.4 YOLOv8l-cls modeli eğitim sonuçları

Class Name	Precision	1-Precision	Recall	1-Recall	f1-score
Yaprak Lekesi	0,9744	0,0256	0,9744	0,0256	0,9744
Sağlıklı	0,9792	0,0208	0,9400	0,0600	0,9592
Külleme	0,968	0,0313	1,0000	0,0000	0,9841

YOLOv8l-cls modelinin ortaya koyduğu sonuçlar için oluşturulan karışıklık matrisi Şekil 5.3.' da gösterilmiştir.



Şekil 5.3 YOLOv8l-cls karışıklık matrisleri


5.3. YOLOv8m-cls Modeli Sınıflandırma Sonuçları

YOLOv8m-cls modeli ile gerçekleştirilen eğitim sonucunda %97,82 oranında doğruluk değeri elde edilmiştir. Yapılan eğitim sonucunda külleme sınıfı yüksek değere sahipken, yaprak lekeli sınıfı ve sağlıklı sınıfı sırasıyla %97,82 ve %96,15 lik değeri elde etmiştir.

Çizelge 5.5 YOLOv8m-cls modeli eğitim sonuçları

Class Name	Precision	1-Precision	Recall	1-Recall	f1-score
Yaprak Lekesi	1,0000	0,0000	0,9573	0,0427	0,9782
Sağlıklı	0,9559	0,0741	1,0000	0,0000	0,9615
Külleme	0,9841	0,0159	1,0000	0,0000	0,9920

YOLOv8m-cls modelinin ortaya koyduğu sonuçlar için oluşturulan karışıklık matrisi Şekil 5.4.' de gösterilmiştir.



Şekil 5.4. YOLOv8m-cls karışıklık matrisleri

5.4. DenseNet121 Modeli Sınıflandırma Sonuçları

DenseNet121 modeli ile gerçekleştirilen eğitim sonucunda %94,44 oranında doğruluk değeri elde edilmiştir. Sonuçlar Çizelge 5.6 'da gösterilmiştir.

Çizelge 5.6 DenseNet121 modeli eğitim sonuçları

Class Name	Precision	1-Precision	Recall	1-Recall	f1-score
Yaprak Lekesi	0,9650	0,0350	0,9324	0,0676	0,9484
Sağlıklı	0,93387	0,0613	0,9563	0,0437	0,9474
Külleme	0,7333	0,2667	1,000	0,0000	0,8462

5.5. ResNet50 Modeli Sınıflandırma Sonuçları

ResNet50 modeli ile gerçekleştirilen eğitim sonucunda %93,39 oranında doğruluk değeri elde edilmiştir. ResNet50 modelide DenseNet121'e yakın sonuçlar ile eğitimi tamamlamış ve eğitim sonuçları Çizelge 5.7' de gösterilmiştir.

Çizelge 5.7 ResNet50 modeli eğitim sonuçları

Class Name	Precision	1-Precision	Recall	1-Recall	f1-score
Yaprak Lekesi	0,9650	0,0350	0,9147	0,0853	0,9392
Sağlıklı	0,9202	0,0798	0,9554	0,0446	0,9375
Külleme	0,6667	0,3333	1,000	0,0000	0,8000

Eğitim sonuçları değerlendirildiğinde YOLOv8 alt modelleri ile yapılan eğitimlerin DenseNet121 ve ResNet modellerine göre daha başarılı sonuçlar elde ettiği görülmektedir. Yapılan eğitim sonuçları literatürde yer alan şeker pancarı yaprak hastalıklarının tespiti ve algılanması konusunda benzer çalışmalarla karşılaştırıldığında YOLOv8x ve YOLOv8m modelleri %97,82 ile başarılı sonuç elde etmiştir.

6. SONUÇ VE ÖNERİLER

Görüntü algılama ve nesne tespit işlemleri günümüzde birçok sektörde yaygın bir şekilde kullanılmaktadır. Kullanılan sektör ve alanlar farklı olsa da genel amaç göz ile tespit edilmesi zor ya da imkânsız olan görüntülerin algılanmasıdır. Tarım alanında da hastalık tespiti, ürünlerin boy veya şekillerine göre gruplandırılması gibi farklı amaçlar için görüntü işleme teknikleri derin öğrenme modelleri ile yapılmaktadır.

Bu tez çalışmasında sağlıklı, külleme ve yaprak lekesi sınıflarına ait şeker pancarı yaprak hastalıklarının tespiti için YOLOv8, ResNet50 ve DenseNet121 derin öğrenme modelleri kullanılmıştır. YOLOv8 modelinin alt modelleri olan YOLOv8x-cls, YOLOv8l-cls ve YOLOv8m-cls ile ResNet50 ve DenseNet121 transfer öğrenme modelleri üzerinden ayrı ayrı eğitim gerçekleştirilmiş ve sonuçları karşılaştırılmıştır. YOLO, derin öğrenme alanında kullanım oranı gün geçtikçe artan ve sürekli olarak yenilenen bir yapıya sahiptir. Gerçekleştirilen eğitimler sonucunda %97,82' lik bir başarı oranı elde edilmiştir. YOLOv8 temelli modeller ulaşılan bu başarı oranı ile şeker pancarı yaprak hastalıklarının sınıflandırılmasında kullanılabilecek bir modeldir.

Ülkemiz ve bölgemiz açısından tarımsal alanda yüksek öneme sahip olan şeker pancarından elde edilecek verimin arttırılması ve şeker pancarı bitkisinde gelişebilecek hastalıkların erken teşhis edilmesi önemlidir. Tespit işlemi şeker pancarı gibi büyük alanlarda ekimi yapılan bitkiler için manuel olarak yapılması hem çok zor, hem de büyük emek, insan gücü ve zaman istemektedir. Derin öğrenme modelleri ile geliştirilecek sistemler yardımıyla bu işlemlerin yapılması her açıdan tasarruf sağlayacaktır.

KAYNAKLAR

- Altaş, Z., Özgüven, M. M., ve Yanar, Y. (2019). Bitki Hastalık Ve Zararlı Düzeylerinin Belirlenmesinde Görüntü İşleme Tekniklerinin Kullanımı: Şeker Pancarı Yaprak Leke Hastalığı Örneği.
- Andaç, İ., Doğan, G., Şengür, A., ve Ergen, B. (2023). Asma Yaprak Türlünün Sınıflandırılması için Doğal ve Sentetik Verilerden Derin Öznitelikler Çıkarma, Birleştirme ve Seçmeye Dayalı Yeni Bir Yöntem. *International Journal of Pure and Applied Sciences*, 9(1), 46-55.
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Aytüre, S., ve Demir, N. (2008). AB- Türkiye ilişkileri sürecinde Türk şeker sektörü simülasyon sonuçları. *Verimlilik Dergisi*, 3, 85-100.
- Başarır, B. (2019). *Derin öğrenme tabanlı nesne takibi* Yüksek Lisans Tezi, Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.
- Bozcu, H. (2024). *Derin öğrenme tabanlı kiraz yapraklarında hasar tespiti* Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilecik.
- Bulut, İ. (2006). *Genel Tarım Bilgileri ve Tarımın Coğrafi Esasları Ziraat Coğrafyası*. Gündüz Eğitim ve Yayıncılık.
- Büşra, E. (2022). Yapay sinir ağı metodu ile bir tekstil firmasında hammadde siparişi için talep tahmini uygulaması= Fabric order demand forecast application in a textile company with the artificial neural network method.
- Çetiner, H. (2021). Yaprak Hastalıklarının Sınıflandırılabilmesi İçin Önceden Eğitilmiş Ağ Tabanlı Derin Ağ Modeli. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 442-456.
- Çoban, F. (2019). *Belirsiz koşullar altında talep tahmini ve gıda işletmesinde bir uygulama* Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.
- Demirdöğen, A. (2022). Türkiye’de şeker: üretim, tüketim, ticaret ve politikaların kısa bir tartışması. *Tarım Ekonomisi Araştırmaları Dergisi*, 8(1), 85-95.
- Dikici, B., Bekçioğulları, M. F., Açıkgöz, H., ve Korkmaz, D. (2022). Zeytin Yaprakındaki Hastalıkların Sınıflandırılmasında Ön Eğitimli Evrişimli Sinir Ağlarının Performanslarının İncelenmesi. *Konya Journal of Engineering Sciences*, 10(3), 535-547.
- Doğan, F., ve Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10-21.

- Ergene, M. C. (2019). *İnsansız hava araçlarında akıllı kontrol sistemlerine yönelik nesne takibi uygulamaları* Yüksek Lisans Tezi, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, Konya.
- Esen, F. A., ve Onan, A. (2022). Derin Öğrenme Yöntemleri ile Bitki Yaprakları Üzerindeki Hastalıkların Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*(40), 151-155.
- Esmer, E. (2009). *Şeker Pancarlarında Yaprak Lekesine Neden Olan Cercospora beticola'nın Klasik ve Moleküler Yöntemlerle Patotiplerinin Belirlenmesi*
- Fedai, R. (2016). Bir Politika Alanı Olarak Şeker ve Şeker Pancarı.
- Gao, J., French, A. P., Pound, M. P., He, Y., Pridmore, T. P., ve Pieters, J. G. (2020). Deep convolutional neural networks for image-based *Convolvulus sepium* detection in sugar beet fields. *Plant methods*, 16, 1-12.
- Girshick, R. (2015). Fast r-cnn. Proceedings of the IEEE international conference on computer vision,
- Gonzalez, S., Arellano, C., ve Tapia, J. E. (2019). Deepblueberry: Quantification of blueberries in the wild using instance segmentation. *Ieee Access*, 7, 105776-105788.
- Gök, İ. (2011). Şekerin Geleceği. *Şeker-İş Sendikası, Ankara*.
- Güneş, E. (2022). *Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması* Yüksek Lisans Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Hallau, L., Neumann, M., Klatt, B., Kleinhenz, B., Klein, T., Kuhn, C., Röhrig, M., Bauckhage, C., Kersting, K., ve Mahlein, A. K. (2018). Automated identification of sugar beet diseases using smartphones. *Plant pathology*, 67(2), 399-410.
- İnternet: İstanbullu, C. (2022). *ML101: Makine Öğrenmesi Nedir?* URL: <https://miuul.com/public/blog/ml101-makine-ogrenmesi-nedir> Son Erişim Tarihi: 02.04.2024
- İnternet: Kabalcı, E. (2024). <https://ekblc.wordpress.com/wp-content/uploads/2013/09/ysa.pdf>. URL: Son Erişim Tarihi: 04.04.2024
- İnternet: Akdoğan, A. (2020). *Uygulamalı Evrişimsel Sinir Ağları (Convolutional Neural Network)*. URL: <https://medium.com/bili%C5%9Fim-hareketi/uygulamal%C4%B1-evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-convolutional-neural-network-7d643eae6a7> Son Erişim Tarihi: 02.04.2024
- İnternet: Keita, Z. (2022). *YOLO Object Detection Explained*. URL: <https://www.datacamp.com/blog/yolo-object-detection-explained> Son Erişim Tarihi: 01.05.2024
- İnternet: Koç, E. (2022). *Evrişimli Sinir Ağlarına Giriş*. URL: <https://miuul.com/blog/evrisimli-sinir-aglarina-giris> Son Erişim Tarihi: 01.03.2024

- İnternet: Cloud, G. *What is Deep Learning?* URL: <https://cloud.google.com/discover/what-is-deep-learning> Son Erişim Tarihi: 01.05.2024
- İnternet: Kuru, N. (2023). *Object Detection ve YOLO*. URL: <https://medium.com/academy-team/object-detection-ve-yolo-27e0b5ecff14> Son Erişim Tarihi: 04.04.2024
- İnternet: Meşeci, E. (2021). *R-CNN Ailesi Part I: R-CNN & Fast R-CNN*. URL: <https://elifmeşeci.medium.com/r-cnn-ailesi-part-i-6aaf775d05d2> Son Erişim Tarihi: 05.03.2024
- İnternet: Mirkhan, A. (2023). *YOLO Algorithm: Real-Time Object Detection from A to Z*. URL: <https://kili-technology.com/data-labeling/machine-learning/yolo-algorithm-real-time-object-detection-from-a-to-z> Son Erişim Tarihi: 01.05.2024
- İnternet: Rohrer, B. (2016). *How do Convolutional Neural Networks work?* URL: https://e2eml.school/how_convolutional_neural_networks_work.html#:~:text=Each%20image%20the%20CNN%20processes%20results%20in%20a%20vote.&text=After%20doing%20this%20for%20every,the%20set%20of%20labeled%20images Son Erişim Tarihi: 02.02.2024
- İnternet: Püsküllü, İ. (2023). *Residual Neural Networks (ResNet): Derin Öğrenmede Çığır Açan Mimariler ve Uygulama Alanları*. URL: <https://medium.com/@ibrahimpuskullu44/residual-neural-networks-resnet-derin-%C3%B6%C4%9Frenmede-%C3%A7%C4%B1%C4%9F%C4%B1r-a%C3%A7an-mimariler-ve-uygulama-alanlar%C4%B1-c3e1667a599b>
- İnternet: Oppermann, A. (2023). *Artificial Intelligence vs. Machine Learning vs. Deep Learning: What's the Difference?* URL: <https://builtin.com/artificial-intelligence/ai-vs-machine-learning> Son Erişim Tarihi: 02.01.2024
- İnternet: Özdemir, D. (2021). *Nesne Tespit Algoritmalarının Gelişimi (Mask R-CNN) — 2*. URL: <https://dilaraozdemir.medium.com/nesne-tespit-algoritmalar%C4%B1n%C4%B1n-geli%C5%9Fimi-mask-r-cnn-2-b622f6f4c2a8> Son Erişim Tarihi: 11.02.2024
- İnternet: Ergin, T. (2018). *Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır?* URL: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad> Son Erişim Tarihi: 02.03.2024
- İnternet: Özgür, C. (2022). *Makine öğrenmesine giriş*. URL: <https://miuul.com/public/blog/makine-ogrenmesine-giris> Son Erişim Tarihi: 01.04.2024
- İnternet: Tekin, B. Y. (2019). *RCNN , YOLO-OpenCV ile Nesne Tanıma*. URL: <https://medium.com/operations-management-t%C3%BCrkiye/rcnn-yolo-opencv-ile-nesne-tan%C4%B1ma-fa3856e69fb3> Son Erişim Tarihi: 01.04.2024
- İpek, A. (2022). *Derin Öğrenme Yöntemi İle Bitki Yaprığı Hastalık Sınıflandırma Çalışması Performans Analizi*. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 25(2), 126-137.

- Karacan, G. (2024). *Derin Öğrenme Yöntemleri Kullanarak Kelebek Türlerinin Birbirlerinden Ayırt Edilmesi* Yüksek Lisans Tezi, Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü, Çankırı.
- Karadeniz, A. T. (2023). *Yaprak Görüntülerini Kullanarak Derin Öğrenme İle Ceviz Türlerinin Belirlenmesi* Doktora Tezi, Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü, Karabük.
- Karahanlı, G., ve Taşkın, C. Derin öğrenme yöntemleri kullanılarak ayçiçeği bitkisinin gelişim evrelerinin tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(3), 1455-1472.
- Karatepe, İ. (2023). *Mask R-Cnn Algoritması İle Askeri Kamuflej Sınıflandırması* Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- Katırcıoğlu, G. (2019). *Denim Kumaşların Görüntü İşleme İle İncelenip Kumaş Hava Geçirgenliğinin Yapay Sinir Ağı İle Tahmin Edilmesi*. Yüksek Lisans Tezi ,Erciyes Üniversitesi. Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Kayseri
- Kaya, F. (2015). Küresel ve bölgesel şeker politikalarının Türkiye şeker fabrikalarına etkilerine bir örnek; Ağrı Şeker Fabrikası. *Coğrafya Dergisi*(31), 41-61.
- Kaya, Ö., ve Çodur, M. Y. (2023). Görme Engelli Yol Tasarımlarının YOLOv8 ile Segmentasyonu. *Interdisciplinary Studies on Contemporary Research Practices in Engineering in the 21st Century-V*, 197.
- Kılıçaslan, S., ve Pacal, I. (2023). Domates Yapraklarında Hastalık Tespiti İçin Transfer Öğrenme Metotlarının Kullanılması. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(2), 215-222.
- Koday, Z., ve Yıldırım, K. (2021). Erzurum ve Çevresinde Şeker Pancarı Tarımı ve Şeker Sanayi. *Doğu Esintileri*(15), 121-147.
- Muzaffer, A. (2021). Derin Öğrenme ile Şeftali Hastalıkların Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*(23), 540-546.
- Özgür, O. (2003). Türkiye Şeker Pancarı Hastalıkları, Türkiye Şeker Fabrikaları AŞ Genel Müdürlüğü. In: Yayın.
- Özgür, O. E. (2011). *Seker Pancari Üretimi (Sugar Beet Production)*. <https://books.google.com.tr/books?id=Yd-JmwEACAAJ>
- Özgüven, M. M., ve Adem, K. (2019). Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. *Physica A: statistical mechanics and its applications*, 535, 122537.
- Öztemel, E. (2003). Yapay sinir ağıları. *PapatyaYayincilik, Istanbul*.

- Öztürk, K., ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Redmon, J., Divvala, S., Girshick, R., ve Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*,
- Ren, S., He, K., Girshick, R., ve Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- Ruuska, S., Hämäläinen, W., Kajava, S., Mughal, M., Matilainen, P., ve Mononen, J. (2018). Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural processes*, 148, 56-62.
- Sargın, A., ve Göçen, A. (2023). *Yapay Zeka Etkinlik Kitabı 1. Şanlıurfa İl Milli Eğitim Müdürlüğü Ar-Ge Birimi*
- Serhatlıoğlu, S., ve Hardalaç, F. (2009). Yapay zeka teknikleri ve radyolojiye uygulanması. *Fırat Tıp Dergisi*, 14(1), 1-6.
- Sevli, Ö. Ü. O. (2022). Elma Bitkisi Hastalıklarının Derin Öğrenme İle Tespiti.
- Sunulu, S., ve Sunulu, A. (2016). Şeker pancarında cercospora yaprak lekesi hastalığı. *Pankobirlik*, 27(108), 34.
- Şeker pancarında Cercospora yaprak lekesi hastalığı (Cercospora beticola sacc.). (2016). *Pankobirlik*.
- Şener, A., ve Ergen, B. (2022). Deprem Sonrası Bina Yüzeylerinde Meydana Gelen Çatlakların Tespitinde Sınıflandırma Modellerinin Karşılaştırılması. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 899-910.
- Terzi, İ., Özgüven, M. M., ve Yağcı, A. (2023). Derin Öğrenme Teknikleri ile Bazı Üzüm Çeşitlerinin Tespiti. *Turkish Journal of Agriculture-Food Science and Technology*, 11(1), 125-130.
- Tosun, F. (2015). Şeker Pancarı ve Şeker, Ürün Raporu. *Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü (TEPGE), Ankara*.
- Türkoğlu, M., Hanbay, K., Sivrikaya, I. S., ve Hanbay, D. (2020). Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334-345.
- Türkşeker. (2021). 2021 Sektör Raporu.
- Weiland, J., ve Koch, G. (2004). Sugarbeet leaf spot disease (Cercospora beticola Sacc.). *Molecular plant pathology*, 5(3), 157-166.

- Yaman, O., ve Tuncer, T. (2022). Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132.
- Yanık, E. (2019). *İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması* Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Yavuz, A. (2021). *Derin öğrenme algoritmaları ile trafik işaret ve levhalarının tanımlanması* Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.
- Yılmaz, A. (2021). *Yapay zekâ*. Kodlab Yayın Dağıtım Yazılım Ltd. Şti.
- Yücel, B. (2023). Şeker Pancarının Gıda Endüstrisi Açısından Önemi. *Uluslararası Sivas Bilim ve Teknoloji Üniversitesi Dergisi*, 2(2), 54-64.



ÖZGEÇMİŞ

Adı-Soyadı : Bilal EYİSOY

Eğitim Derecesi	Okul/Program	Mezuniyet Yılı
Lisans	Selçuk Üni. / Bilgisayar Sist. Öğretmenliği	2002
Yüksek Lisans (Tezsiz)	Amasya Üni. / Teknoloji Ve İnovasyon Yönetimi	2021
Lisans	Cumhuriyet Üniversitesi Bilgisayar Mühendisliği	2021

Yabancı Dil : İngilizce

İş Deneyim/Yıl	Kurum
2002-2007	Atatürk Anadolu Teknik Lisesi, Anadolu Meslek Lisesi, Teknik Lise ve Endüstri Meslek Lisesi / Erzurum
2007-	İldeş Hatun Mesleki ve Teknik Anadolu Lisesi / Amasya

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

1-) Eyisoy, B. ve Ünal, Y. (2022). Classification Of Siirt And Kirmizi Type Pistachio With Some Pretrained Deep Learning Models Istanbul International Modern Scientific Research Congress, İstanbul.