



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

**CEVİZ HASTALIKLARININ DERİN ÖĞRENME İLE  
SINIFLANDIRILMASI**

**YÜKSEK LİSANS TEZİ**

**KADİR AYGÜN**

**HAZİRAN**

**KADİR AYGÜN**

**TEKNOLOJİ VE İNOVASYON  
YÖNETİMİ ANABİLİM DALI**

**HAZİRAN 2024**

CEVİZ HASTALIKLARININ DERİN ÖĞRENME İLE  
SINIFLANDIRILMASI

Kadir AYGÜN

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

Kadir AYGÜN tarafından hazırlanan “Ceviz 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 Bilimleri Anabilim Dalı, Tokat Gazi Osman Paşa 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 kayıplarımı kabullendiğimi beyan ederim.

(İmza)

Kadir AYGÜN

27 / 06 / 2024

# CEVİZ HASTALIKLARININ DERİN ÖĞRENME İLE SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Kadir AYGÜN

AMASYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2024

## ÖZET

Ceviz, ülkemizde hem gıda hem de ağaç endüstrisi için yetiştirilen önemli bir bitkidir. Cevizde çeşitli çevresel faktörlerin de etkisiyle bazı hastalıklar ve mineral eksiklikleri ortaya çıkabilmektedir. Bu hastalıklar ve mineral eksiklikleri, ceviz yapraklarında farklı şekillerde kendini göstermektedir. Ceviz üreticileri, ceviz verimliliğini doğrudan etkileyen birtakım hastalıklar ve beslenme yetersizlikleri ile mücadele etmek için yeni nesil teknolojilerden yardım almaktadırlar. Son yıllarda birçok sektörde olduğu gibi tarım sektöründe de çeşitli problemlerin çözümünde derin öğrenme yöntemleri kullanılmaktadır. Bu çalışmada, ceviz yapraklarında görülen ceviz antraknozu ve vitamin yetersizliklerinin tespiti ve sınıflandırılması için Faster R-CNN modeli geliştirilmiştir. Geliştirilen model için biri sağlıklı, diğer üçü hastalıkları içeren dört sınıftan oluşturulan veri seti kullanılmıştır. Geliştirilen model, GoogleNet, AlexNet ve SqueezeNet gibi bazı ön eğitilmiş derin öğrenme modelleri ile de test edilerek sınıflandırma başarısı irdelenmiştir. Her bir CNN model için Adam ve SGDM optimizasyon algoritmaları ile farklı iterasyon sayılarının sınıflandırma başarısına etkisi incelenmiştir. Modellerin hassasiyet (precision), doğruluk (accuracy), F1 skoru ve hatırlama (recall) gibi metrik değerleri hesaplanarak tutarlılıkları değerlendirilmiştir. Çalışmada geliştirilen Faster R-CNN modelinin sınıflandırmada ki doğruluğu %98,28 olarak bulunmuştur.

Sayfa Adedi : 52  
Anahtar Kelimeler : Ceviz, Hastalık, Faster R-CNN, Derin Öğrenme  
Danışman : Dr. Öğr.Üyesi Yavuz ÜNAL

# CLASSIFICATION OF WALNUT DISEASES WITH DEEP LEARNING

(M. Sc. Thesis)

Kadir AYGÜN

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2024

## ABSTRACT

Walnut is an important plant grown for both food and wood industry in our country. Some diseases and mineral deficiencies may occur in walnut with the effect of various environmental factors. These diseases and mineral deficiencies manifest themselves in different ways in walnut leaves. Walnut producers are getting help from new generation technologies to combat some diseases and nutritional deficiencies that directly affect walnut productivity. In recent years, deep learning methods have been used to solve various problems in the agricultural sector as in many sectors. In this study, Faster R-CNN model was developed for the detection and classification of walnut anthracnose and vitamin deficiencies in walnut leaves. For the developed model, a dataset consisting of four classes, one of which is healthy and the other three are diseases, was used. The developed model was also tested with some pre-trained deep learning models such as GoogleNet, AlexNet and SqueezeNet and its classification success was analysed. For each CNN model, the effect of different iteration numbers on classification success was examined with Adam and SGDM optimisation algorithms. Metric values such as accuracy, precision, recall and F1 score of the models were calculated and their consistency was evaluated. The classification accuracy of the Faster R-CNN model developed in the study was found to be 98.28%.

Number of pages : 52

Keywords : Walnut, Disease, Faster R-CNN, Deep Learning

Supervisor : Asst. Prof. Dr. Yavuz ÜNAL

## ÖNSÖZ VE TEŞEKKÜR

Tez çalışmamın yürütülmesinde destek ve emeklerini hiçbir zaman esirgemeyen tez danışmanım sayın Dr. Öğr. Üyesi Yavuz ÜNAL'a, çalışmalarımda bilgi ve tecrübesi ile desteğinden dolayı sevgili arkadaşım sayın Öğr. Gör. Hadi ESMERAY'a ve süreçte bana destek olan tüm mesai arkadaşlarıma en içten teşekkürlerimi sunarım.

Çalışmalarım süresince her daim yanımda olan ve desteklerini esirgemeyen sevgili eşim ile, çocuklarım Erdem ve Kerem AYGÜN'e sonsuz sevgi ve saygılarımı sunarım.



## İÇİNDEKİLER

	Sayfa
ÖZET .....	iv
ABSTRACT .....	v
ÖNSÖZ VE TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELER DİZİNİ.....	ix
ŞEKİLLER DİZİNİ .....	x
RESİMLER DİZİNİ .....	xi
SİMGELER VE KISALTMALAR DİZİNİ .....	xii
1. GİRİŞ.....	1
1.1. Literatür Taraması.....	2
2. TEMEL KAVRAMLAR .....	6
2.1. Makine Öğrenmesi.....	6
2.2. Derin Öğrenme.....	6
2.3. Konvolüsyonel Sinir Ağları (CNN).....	7
2.3.1. Giriş Katmanı.....	8
2.3.2. Konvolüsyon (Evrışim) Katmanı.....	8
2.3.3. Aktivasyon Katmanı .....	10
2.3.4. Tam Bağlı (Full-Connected) Katman .....	10
2.3.5. Havuzlama (Pool) Katmanı.....	11
2.3.6. Softmax Katmanı .....	12
2.3.7. Diğer Katman ve Kavramlar .....	12
2.4. Faster R-CNN .....	13
2.5. Ön Eğitimli Evrışimsel Sinir Ağı Modelleri .....	16

2.5.1. GoogleNet.....	16
2.5.2. AlexNet.....	17
2.5.3. SqueezeNet .....	18
2.6. Performans Metrikleri.....	20
3. CEVİZ HASTALIKLARI VE BESİN YETERSİZLİĞİ .....	22
3.1. Ceviz Yaprak Hastalıkları.....	22
3.1.1. Ceviz Antraknozu .....	22
3.2. Cevizde Besin Yetersizliği.....	23
3.2.1. Ceviz Bitkisinde Bor(B) Eksikliği .....	24
3.2.2. Ceviz Bitkisinde Demir(Fe) Eksikliği .....	24
3.2.3. Ceviz Bitkisinde Magnezyum(Mg) Eksikliği .....	25
3.2.4. Ceviz Bitkisinde Potasyum(K) Eksikliği .....	26
4. MATERYAL VE YÖNTEM.....	27
4.1. Çalışmada Kullanılan Yazılım ve Donanımlar .....	27
4.2. Geliştirilen Yöntem.....	28
4.3. Veri Seti .....	30
4.4. Veri Büyütme (Data Augmentation).....	32
4.5. Optimizasyon Algoritmaları .....	33
5. DENEYSEL UYGULAMA .....	35
6. SONUÇ VE ÖNERİLER.....	47
KAYNAKLAR .....	48
ÖZGEÇMİŞ .....	52

## ÇİZELGELER DİZİNİ

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 2.1. R-CNN, Fast R-CNN, Faster R-CNN modellerin performans karşılaştırması	16
Çizelge 4.1. Veri setindeki görüntü sayılarının sınıflara göre dağılımı .....	33
Çizelge 5.1. Veri setini oluşturan sınıflar ve görüntü sayıları .....	35
Çizelge 5.2. Geliştirilen modelin test işleminde seçilen CNN hiperparametreleri .....	36
Çizelge 5.3. 10 iterasyon değerinde CNN modellerin performans karşılaştırması.....	37
Çizelge 5.4. 30 iterasyon değerinde CNN modellerin performans karşılaştırması.....	38
Çizelge 5.5. 50 iterasyon değerinde CNN modellerin performans karşılaştırması.....	39
Çizelge 5.6. 100 iterasyon değerinde CNN modellerin performans karşılaştırması.....	40
Çizelge 5.7. Literatürde Faster R-CNN modeli ile yapılmış sınıflandırma çalışmalarının karşılaştırması .....	45

## ŞEKİLLER DİZİNİ

<b>Şekil</b>	<b>Sayfa</b>
Şekil 2.1. Bir sinir ağının üç ana aşaması .....	7
Şekil 2.2. Evrimsel sinir ağlarının temel katmanları .....	8
Şekil 2.3. 5x5x3 boyutlu görüntünün 3x3 boyutlu filtre ile konvolüsyon işlemi (İnik ve Ülker, 2017).....	9
Şekil 2.4. Tam bağlı katman yapısı.....	10
Şekil 2.5. En büyük havuzlama (max pooling) örneği.....	11
Şekil 2.6. Görüntü sınıflandırma ile nesne algılama arasındaki fark.....	14
Şekil 2.7. R-CNN mimarisi.....	14
Şekil 2.8. Faster R-CNN mimarisi.....	15
Şekil 2.9. GoogleNet Mimarisi (Kaya).....	17
Şekil 2.10. AlexNet Mimarisi Yapısı.....	18
Şekil 2.14. SqueezeNet makro mimari görünümü (Iandola ve diğerleri, 2016). .....	19
Şekil 2.15. Karışıklık matrisi (Confusion matrix) .....	20
Şekil 4.1. Geliştirilen Faster R-CNN modelin blok diyagramı.....	28
Şekil 4.2. Geliştirilen modelin detaylı gösterimi .....	29
Şekil 4.3. Geliştirilen Faster R-CNN modelin katmansal yapısı .....	30
Şekil 4.4. Data Augmentation uygulanmış ceviz yaprağı örnekleri. ....	32
Şekil 5.1. Geliştirilen modele ait 30 epoch ve Adam algoritması için karışıklık matrisi ....	41
Şekil 5.2. Geliştirilen model için accuary-loss grafiği.....	42
Şekil 5.3. AlexNet'e ait 100 epoch ve SDGM algoritması için karışıklık matrisi.....	43
Şekil 5.4. GoogleNet'e ait 100 epoch ve SDGM algoritması için karışıklık matrisi.....	44
Şekil 5.5. SqueezeNet'e ait 100 epoch ve SDGM algoritması için karışıklık matrisi.....	45

**RESİMLER DİZİNİ**

<b>Resim</b>	<b>Sayfa</b>
Resim 3.1. Ceviz Antraknozu .....	23
Resim 3.2. Bor elementi eksikliği görülen ceviz yaprağı .....	24
Resim 3.3. Demir eksikliği olan ceviz yaprağı görüntüsü .....	25
Resim 3.4. Magnezyum eksikliği olan ceviz yaprağı görüntüsü .....	25
Resim 3.5. Potasyum eksikliği olan ceviz yaprağı görüntüsü .....	26
Resim 4.1. Sağlıklı örnek yaprak görselleri.....	31
Resim 4.2. Ceviz antraknozu (Antraknoz) olan ceviz yaprağı örnekleri.....	31
Resim 4.3. Mineral eksikliği (Vitaminsiz) olan ceviz yaprağı örnekleri.....	31
Resim 4.4. Ceviz antraknozu + mineral eksikliği (Her iki hastalık) olan ceviz yaprağı görselleri.....	32
Resim 5.1. Sağlıklı, antraknozlu, vitaminsiz ve her iki hastalığa sahip görüntüler.....	35

## SİMGELER VE KISALTMALAR DİZİNİ

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

### Simgeler

### Açıklama

$f$	Giriş görüntüsü
$g$	Filtre
G1	Giriş verisi buyutunun genişlik değeri
G2	Giriş verisi buyutunun yükseklik değeri
D1	Giriş verisi buyutunun derinlik değeri
D2	Çıkış verisi buyutunun derinlik değeri
F	Filtre Boyutu
A	Adım sayısı

### Kısaltmalar

### Açıklama

ADAM	Adaptive Moment Estimation
CNN	Convolutional Neural Network
CPU	Merkezi İşlem Birimi
DL	Deep Learning
DVM	Destek vektör makinesi
ESA	Evrişimsel Sinir Ağı
FN	Yanlış Negatif
FP	Yanlış Pozitif
GPU	Graphics Processing Unit

ILSVRC	ImageNet Large Scale Visual Recognition Challenge
MATLAB	Matris laboratuvarı
ML	Machine Learning
NMS	Non-Maximum Suppression
PSO	Parçacık Sürü Optimizasyonu
ReLU	Rectified Linear Units
RGB	Red Green Blue
RPN	Bölge Önerme Ağı
SGD	Stochastic Gradient Descent
SGDM	Stochastic Gradient Descent with Momentum
SSD	Single Shot Detector
SVM	Support Vector Machine
TN	Doğru Negatif
TP	Doğru Pozitif
YSA	Yapay Sinir Ağı

## 1. GİRİŞ

Ceviz, dünya genelinde hem gıda hem de ağaç endüstrisi açısından önemli bir meyve ve ağaç türü olarak yetiştirilen, ekonomik açıdan büyük değere sahip bir bitkidir. Geniş kullanım alanları nedeniyle, ceviz, birçok ülkede tarımsal üretimin ve ticaretin vazgeçilmez bir parçası haline gelmiştir. Ceviz, hem besin değeri yüksek bir gıda maddesi olarak tüketilirken, aynı zamanda dayanıklı ve kaliteli odun elde etmek amacıyla da yetiştirilir. Bu nedenle, ceviz ağacı, tarımsal ekonomiye önemli katkılar sağlar ve birçok çiftçinin geçim kaynağını oluşturur. Ancak, ceviz yetiştiriciliği, çeşitli çevresel olumsuzluklara maruz kalabilmektedir. Bu çevresel olumsuzluklar arasında yaprak hastalıkları ve mineral yetersizlikleri de bulunmaktadır.

Ceviz yapraklarında, fungal, bakteriyel ve viral patojenlerin neden olduğu çeşitli hastalıklar görülebilir. Bu hastalıklar, yaprak lekeleri, küf mantarları ve benzeri semptomlarla kendini gösterir. Ayrıca, mineral yetersizlikleri de ceviz yapraklarında belirgin izler bırakır; bu yetersizlikler, yaprak renginde solma, sararma ve yaprak deformasyonu gibi belirtilerle ortaya çıkar. Hem yaprak hastalıkları hem de mineral yetersizlikleri, ceviz ağacının büyümesini, gelişmesini ve verimliliğini olumsuz etkileyerek ceviz yetiştiriciliğinde ciddi ekonomik kayıplara yol açabilir.

Bu sorunlar, ceviz yetiştiriciliğinin sürdürülebilirliği ve karlılığı açısından büyük önem taşımaktadır. Dolayısıyla, ceviz ağaçlarının sağlık durumunun düzenli olarak izlenmesi, hastalık ve mineral yetersizliklerinin erken teşhis edilmesi, uygun tedavi ve besleme yöntemlerinin uygulanması gerekmektedir. Böylece, ceviz ağaçlarının sağlığı korunarak, verimlilik ve kalite artırılabilir, ekonomik kayıplar en aza indirilebilir.

Ceviz yaprak hastalıkları ve mineral yetersizliklerinin tespit edilmesi ya da sınıflandırılmasının uzman gözlemciler tarafından yapılması gerekmektedir. Uzman kontrolü, çoğu durumda zaman alıcı ve maliyetli olabilmekte bazen de doğru bir şekilde problemin tespiti için yeterli olmayabilmektedir. Bu nedenle, derin öğrenme modellerinin kullanımı, ceviz yaprağı hastalıkları ve mineral yetersizliklerinin hızlı, doğru ve maliyetsiz bir şekilde tespit edilip sınıflandırılmasında önemli bir yere sahiptir.

Bu çalışmada, ceviz yapraklarında en çok karşılaşılan ceviz antraknozu hastalığı ile bazı mineral yetersizliklerinin otomatik teşhisi ve sınıflandırılması için Faster R-CNN derin öğrenme modelinin kullanımını araştırmayı amaçlıyoruz. Derin öğrenme algoritmalarının, görüntü işleme ve sınıflandırma problemlerindeki etkinliği ve doğruluğu dikkate alındığında, bu tekniklerin ceviz yaprak hastalıkları ve mineral yetersizliklerinin teşhisinde güçlü bir potansiyele sahip olduğunu düşünüyoruz.

Bu çalışma, ceviz yetiştiriciliği kapsamında ceviz yapraklarında görülen ceviz antraknozu hastalığı ve bazı mineral yetersizliklerinin hızlı ve doğru bir şekilde teşhis edilmesine yardımcı olacak yeni bir yaklaşım sunmayı hedeflemektedir. Elde edilen sonuçlar, ceviz yetiştiricileri ve uzman kişilerin ağaçlardaki hastalık ya da besin-mineral yetersizliklerini belirlemesi ve zamanında gerekli tedbirleri alması konusunda önemli katkılar sağlayabilir.

### **1.1. Literatür Taraması**

Evrişimsel sinir ağı yöntemlerinden olan Faster R-CNN ile çürük ve sağlam elmaların tespiti ve sınıflandırılmasına yönelik bir çalışma yapılmıştır (Cömert, Hekim, ve Adem, 2019). Çalışmada farklı açılardan çekilmiş 1200 adet görüntü elde edilmiştir. Görüntüler bir dizi ön işleme aşamasından geçirildikten sonra Faster R-CNN önerilen modeli ile çürük tespiti yaptırılarak “Çürük / Sağlam” şeklinde sınıflandırılmıştır. Yapılan çalışma neticesinde önerilen Faster R-CNN modeli ile %84,95 oranında sınıflandırma başarısı elde edilmiştir.

Üzüm ve üzüm yapraklarında görülen hastalıkların sınıflandırılması için önceden eğitilmiş olan derin öğrenme modellerinden Faster R-CNN InceptionV2 ve SSD MobilenetV1 kullanılarak yapılan çalışmada iki farklı veri seti kullanılmıştır. İlk veri seti ile yapılan çalışmada Faster R-CNN InceptionV2 modelinde %95,57 ve SSD MobilenetV1 modelinde %59,29 oranında ortalama doğruluk oranı elde edilmiştir. İkinci veri seti ile yapılan çalışmada ise Faster R-CNN InceptionV2 modelinde %91,61 ve SSD MobilenetV1 modelinde %18 oranında ortalama doğruluk oranı elde etmiştir (Ghoury, 2019).

Zeytin yapraklarına göre zeytin bitkisinin sınıflandırılması amacıyla (Uysal, 2020), yaptığı tez çalışmasında 3400 adet zeytin yaprağı görüntüsü ile zeytin bitkisine ait 3 farklı yaprak türünü sınıflandırmıştır. VGG16 ve VGG19 CNN modelleri ile yaptığı sınıflandırma çalışmasında %88 oranda doğruluk ile VGG16 modelinde en başarılı sonucu elde etmiştir.

Sonrasında önerilen ağ modeline, keras kütüphanesi ImageDataGenerator sınıfıyla veri artırım işlemi yaparak Adam optimizasyon algoritması ile 100 iterasyon değerinde modeli eğitmiştir. Veri artırım işlemi sonucunda da önerilen CNN modeli ile %94 doğruluk oranı ile sınıflandırma başarısı elde etmiştir.

Elma bitkisinde (Aksoy, Halis, ve Salman, 2020), uyuz, siyah çürük ve pas hastalığına sahip yapraklardan oluşan veri setinde evrimsel sinir ağı modelleri (CNN) kullanılarak hastalık tespiti yaptırmaya çalışmıştır. VGG16-BN, AlexNet, DenseNet-121, SqueezeNet1\_0 ve ResNet-34 mimarilerinin karışıklık matrisine göre performans değerlendirmesi yaptığında elma bitkisindeki hastalıkların tespit edilmesinde en iyi modelin Resnet-34 olduğunu belirtmiştir.

Mısır yapraklarında oluşan yaprak yanığı, mısır pası ve gri yaprak lekesi tespit ve sınıflandırılmasına yönelik çalışma yapılmıştır (Göksu, Sünnetci, ve Alkan, 2021). Yapılan çalışmada EfficientNetB5 ağı ile evrimsel sinir ağı tabanlı 2 model geliştirilmiş ve bu modellerin performans metrik değerlerini artırabilmek için veri setine büyütme, aynalama, döndürme gibi veri çoğaltma teknikleri uygulanmıştır. Çalışmanın sonunda EfficientNetB5 modeli ile %92,12, geliştirilen derin öğrenme modeli ile de %89,88 lik bir başarı oranı elde etmiştir.

2021 yılında şeftali ağaçlarında bazı hastalıkların tespit ve sınıflandırılması için yapılan çalışmada AlexNet evrimsel sinir ağı modeli ile şeftali ağaçlarındaki koşnili ve monilya hastalıklarının tespit edilmeye çalışılmıştır. (Aslan, 2021). Gerçek hastalık görüntülerinden oluşan veri seti ile yapılan deneysel çalışmada hastalıklar %99,30 oranında tespit edilmiştir.

Domates sağlıklı yaprakları ile 9 farklı domates yaprağı hastalığını tespit etmek için (Ecemiş, 2022), T-Leafnet Evrimsel Sinir Ağı modelini önermiştir. Çalışmasında önerdiği ağ modelini sıfırdan eğiterek elde ettiği sınıflandırma başarısını diğer hazır ağ modelleri MobileNetV2, AlexNet ve VGG16 veri kümeleri ile de eğiterek sonuçlarını karşılaştırmıştır. Çalışma sonucunda MobileNetV2, T-LeafNet, VGG16 ve AlexNet ağlarının sınıflandırma performanslarını sırasıyla %99.1, %97.32, %99.21 ve %98.32 olarak ölçmüş, sınıflandırma performansları ile eğitim zamanları bir arada değerlendirildiğinde T-Leafnet önerilen ağ modelinin diğer bilinen ağ modellerine göre daha kısa sürede ve az kaynakla sınıflandırma başarısı elde ettiğini gözlemlemiştir.

Narenciye de yaprak hastalıklarını sınıflandırmak için (Çetiner ve Çetiner, 2022) bir derin öğrenme modeli geliştirmişler ve buna ek olarak ResNet50, MobileNetV2, ve DenseNet121 modelleri ile yaprak hastalıklarını sınıflandırmışlardır. 3 farklı hastalığın sınıflandırmasında %100, %100 ve %98 gibi başarı oranları elde etmişlerdir.

Hastalıklı ceviz yaprakları görüntü veri seti ile (Yaman ve Tuncer, 2022), yaptıkları çalışmada 726 adet ceviz yaprağı görüntüsünü sağlıklı ve hastalıklı olarak iki sınıfta toplayarak 17 farklı derin öğrenme medeli ile bu görüntüleri sınıflandırmak için test etmiş ve aralarından en iyi iki modelin DarkNet53 ve ResNet101 olduğunu belirlemişlerdir. ReliefF algoritması ile bu iki modelden hibrit bir özellik çıkarımı elde etmiş ve bu özellikleri destek vektör makinesi (DVM) algoritması kullanarak %99,58 doğruluk oranına sahip bir sınıflandırma işlemi gerçekleştirmişlerdir.

Farklı ceviz türlerinin sınıflandırılması amacıyla (Kayaalp ve Altınalan, 2023) yaptıkları çalışmada cevizin, toprağa ve uygun iklim koşullarına göre türlerinin seçilip dikilmesi gerektiğini ifade etmiş, ceviz bitkisinin 4-5 yıl süre sonunda yetişip meyve vereceğini, ancak bu süre sonunda cevize ait gerçek bir sınıflandırmadan bahsedilebileceğini ifade etmişlerdir. Yaptıkları çalışmada daha erken sürelerde aldıkları ceviz sürgün görsellerini derin öğrenme modelleri ile sınıflandırmayı amaçlamışlardır. 10 farklı ceviz türünden oluşan 3552 ceviz görüntü veriseti ile yaptıkları çalışmada EfficientNet derin öğrenme modeli ile %91,87 doğruluk oranı ile başarılı sınıflandırma yapmışlardır.

Gül yapraklarındaki hastalıklarla ilgili (Gülmez, 2023), gül yaprakları veriseti ile yaptığı çalışmada gül yapraklarındaki hastalıkların tespit edilmesi ve sınıflandırılması amacıyla evrişimli sinir ağlarını kullanan derin öğrenme modelleri ile siyah nokta, tüylü küf ve hastaliksız şekilde sınıflandırma çalışması yapmıştır. Çalışmasında Xception, VGGNet, ResNet gibi CNN modelleri ile test yapmış ve parçacık sürü optimizasyonu (PSO) ile optimize edilmiş modelin en iyi olduğu sonucuna ulaşmıştır.

Bağcılıkta verimi olumsuz yönde etkileyen bazı bağ hastalıklarının (mildiyö, yaprak kıvrılma virüs hastalığı, külleme, ölü kol hastalığı, asma kısa boğum virüs hastalığı) tespiti ve sınıflandırılması amacıyla doktora çalışması yapılmıştır (Altaş, Özgüven, ve Adem, 2023). Çalışmada, Faster R-CNN, SSD Multibox ve Özgün yeni geliştirilen modelin 11000 görüntü kullanılarak eğitilerek hastalık tespit ve sınıflandırma başarıları ölçülmüştür.

Deneyisel çalımlar sonucunda özgün yeni geliştirilen model, SSD Multibox ve Faster R-Cnn modellerinin sınıflandırma başarı oranları sırası ile %96,95, %92,21 ve %92 olarak tespit edilmiştir.

Dişlerdeki çürük seviyesinin tespiti ve sınıflandırılması amacıyla yapılan çalışmada 553 adetten oluşan röntgen film veri seti kullanılmıştır. Faster R-CNN ve YOLOv5 modelleri ile yapılan deneysel çalışmalarda kanal, dolgu ve köprü şeklinde sınıflandırma başarı oranları ölçülmüştür. Çalışma sonucunda Faster R-CNN modeli ile %86,7 ve YOLOv5 modeli ile %92,7 doğruluk değerlerine ulaşılmıştır (Ünsal ve Adem, 2023).

Kanser tespit yöntemlerinden biri olan Manyetik Rezonans (MR) görüntüleme tekniği ile elde edilen Mammogram görüntüleri kullanılarak meme kanserinin tespiti ve sınıflandırılması amacıyla bir tez çalışması yapılmıştır (Biçici, 2023). Yapılan tez çalışmasında “The Digital Database for Screening Mammography-DDSM” açık kaynak veri tabanından alınan 500 adet kanserli ve normal görüntülerden oluşan veri seti kullanılmıştır. Görüntülerdeki lezyonlar uzman radyologlar tarafından belirlenerek LabelImg etiketleme aracı kullanılarak XML dosyası haline getirilmiştir. Çalışmada Faster R-CNN derin öğrenme modeli ile birlikte kullanılan Inception v2, Resnet101 ve Resnet50 modellerin lezyonları belirlemedeki başarı doğruluk oranları sırasıyla %97,16, %94,74 ve %99,63 olarak tespit edilmiştir.

Kabuklu fındıkta çatlak, delik ya da kırık gibi kusurlu fındıkların görüntü işleme yöntemleri kullanılarak otomatik olarak tespiti ve sınıflandırılması amacıyla çalışma yapılmıştır. Yapılan deneysel çalışmada Facebook firması tarafından geliştirilen Detectron2 uygulamasında Faster R-CNN modeli çalıştırılarak kabuklu fındıklar sağlam ve kusurlu olarak iki sınıfa ayrılmıştır. Elde edilen sınıflandırma başarı oranı mAP ölçeğine göre %92 olarak tespit edilmiştir (Kıvrak ve Gürbüz, 2023).

Kiraz yapraklarında hastalık tespiti için (Bozcu, 2024), iki farklı veri seti kullanarak derin öğrenme modellerinin performansını incelemiştir. Çalışma sonucunda MobileNet-V2 ve önerilen CNN+LSTM modelleri ile en iyi sonuçları elde ettiğini belirtmiştir. Çalışmasında ayrıca çeşitli veri setleri kullanılarak güvenilirliğin daha da artırılabilceğini, farklı derin öğrenme modelleri kullanılarak hastalık tespitinde başarı oranlarının daha da yükseltilebileceğini ifade etmiştir.

## 2. TEMEL KAVRAMLAR

Makine öğrenmesi, derin öğrenme ve konvolüsyonel sinir ağları, yapay zeka teknolojilerinin en temel bileşenleridir. Bu teknolojiler, karmaşık problemleri çözmek ve daha akıllı sistemler geliştirmek için günümüzde yaygın olarak kullanılmaktadır. Bilhassa Faster R-CNN gibi gelişmiş modeller, nesne algılama ve sınıflandırma işlemlerinde yüksek performans ve doğruluk sağlamaktadır. Bu bölümde makine öğrenmesi, derin öğrenme, Faster R-CNN kavramlarının yanı sıra bazı evrimsel sinir ağı modelleri ayrıntılı olarak incelenecektir.

### 2.1. Makine Öğrenmesi

Makine öğrenmesi (Machine Learning) bir problemin eldeki bulgulara dayanarak bilgisayar tabanlı algoritmalarla çözülmesini amaçlar. Makine öğrenmesinde el ile işlenmesi zor, uzmanlık gerektiren ya da zaman alan veriye dayalı en uygun model oluşturulur. (Öztürk ve Şahin, 2018). Özellikle belirsizlik ve karar verme sürecinin zor olduğu problemlerin çözümü için farklı makine öğrenmesi yöntemleri geliştirilmiştir. Bu yöntemler arasında denetimli, denetimsiz ve pekiştirmeli öğrenme gibi makine öğrenme yöntemleri yer almaktadır (Gökçalp, 2022).

Makine öğrenmesi, sağlık, finans, tarım, perakende gibi pek çok sektörde yaygın olarak kullanılmaktadır. Örneğin elde edilen görüntüler üzerinden hastalık tespiti yapılması ya da bir e-ticaret uygulamasının müşteriye kişileştirilmiş önerilerde bulunması gibi her türden pek çok uygulamalar geliştirmek makine öğrenmesi ile mümkün hale gelmiştir.

### 2.2. Derin Öğrenme

Derin öğrenme, çok katmanlı yapay sinir ağlarına getirilen yeni bir yaklaşım olarak ortaya çıkmış bir makine öğrenmesidir (Kuş, 2019). Çok katmanlı sinir ağları olarak da ifade edilen derin konvolüsyonel sinir ağları ile sınıflandırma, sinyal işleme, nesne tespiti, video ve görüntü analizi, gibi pek çok konuda bir çok çalışma yapılmış ve yüksek başarımlı sonuçlar elde edilmiştir.

Bir sinir ağı Şekil 2.1’de görüldüğü üzere “ön işlem- özellik çıkarımı-sınıflandırma ve tespit” şeklinde üç ana aşamadan oluşur. Her üç aşamada da doğruluğu artırmaya yönelik çalışmalar yapılırken özellik çıkarımı aşamasında tespit edilmesi istenen olay ya da görsele ait belirgin hususlar elde edilmeye çalışılır. Sınıflandırma ve tespit aşamasında ise elde edilen belirgin özelliklerden hareketle yapay sinir ağları kullanılarak sınıflandırma işlemi gerçekleştirilir (Doğan ve Türkoğlu, 2019).



Şekil 2.1. Bir sinir ağının üç ana aşaması

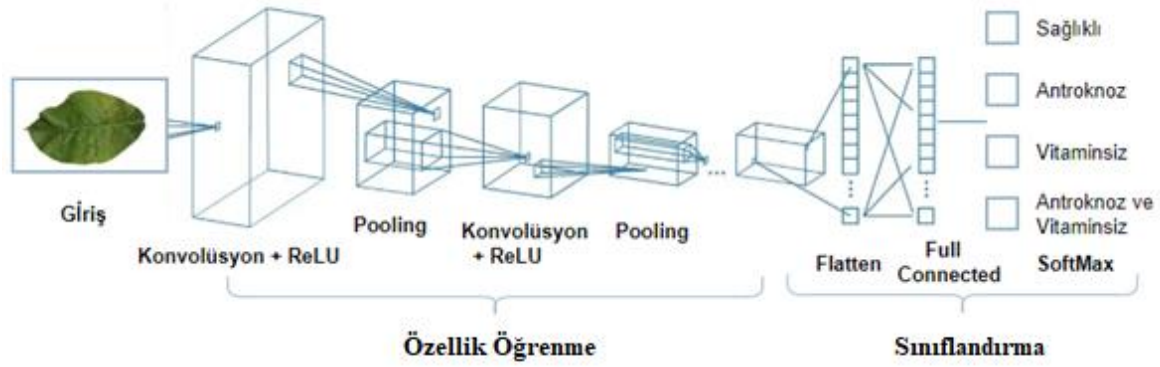
Derin konvolüsyonel sinir ağlarında ön işlem ve özellik çıkarımı gibi aşamalar göz ardı edilmekte ve kullanılacak derin sinir ağı içerisinde yer alan katmanlarda otomatik olarak belirlenmektedir. Konvolüsyonel sinir ağının yapısında yer alan katmanlar içerisinde gerekli ön işlem ve belirgin özellik çıkarımları yapılarak sonraki katmanlara otomatik olarak aktarılmaktadır (Hinton, Srivastava, Krizhevsky, Sutskever, ve Salakhutdinov, 2012).

### 2.3. Konvolüsyonel Sinir Ağları (CNN)

Türkçe evrişimsel sinir ağı olarakta bilinen konvolüsyonel sinir ağları (CNN) çok katmanlı ve ileri beslemeli bir yapay sinir ağıdır. Genellikle hastalık tespiti, ses ve yüz tanıma, görüntü sınıflandırma, nesne tespiti gibi bilhassa görüntü analizlerinin yapılmasında yaygın olarak kullanılır. 1998 yılında LeCun ve arkadaşları tarafından ilk konvolüsyonel sinir ağı oluşturulmuş LeNet adını almıştır. Sonraki yıllarda AlexNet (2012), ZFNet (2013), VGGNet (2014), GoogleNet (2015) ve Resnet (2015) gibi günümüzde yaygın olarak kullanılan birçok ön eğitilmiş evrişimsel sinir ağı mimarileri ortaya çıkmıştır (Doğan ve Türkoğlu, 2019).

CNN’ler, görüntüler üzerinde farklı boyutlarda konvolüsyon matrisleri kullanılarak filtreleme yapar ve bu şekilde görüntülerdeki özniteliklerin belirgin hale gelmesini sağlar. ESA mimarilerinin bu öznitelikleri kendi kendine çıkarabiliyor olması önemli bir avantajdır.

Derin öğrenme yapıları içerisinde en çok kullanılan sinir ağı Evrişimsel sinir ağıdır. ESA modelleri temelde beş ana katmandan oluşmaktadır. Bunlar; giriş katmanı, evrişim (konvolüsyon) katmanı, havuzlama (pooling) katmanı, tam bağlı katman ve çıkış katmanlarıdır (Karadeniz, 2023). Şekil 2.2’ de bir evrişimsel sinir ağının beş temel katmansal yapısı gösterilmektedir.



Şekil 2.2. Evrişimsel sinir ağlarının temel katmanları

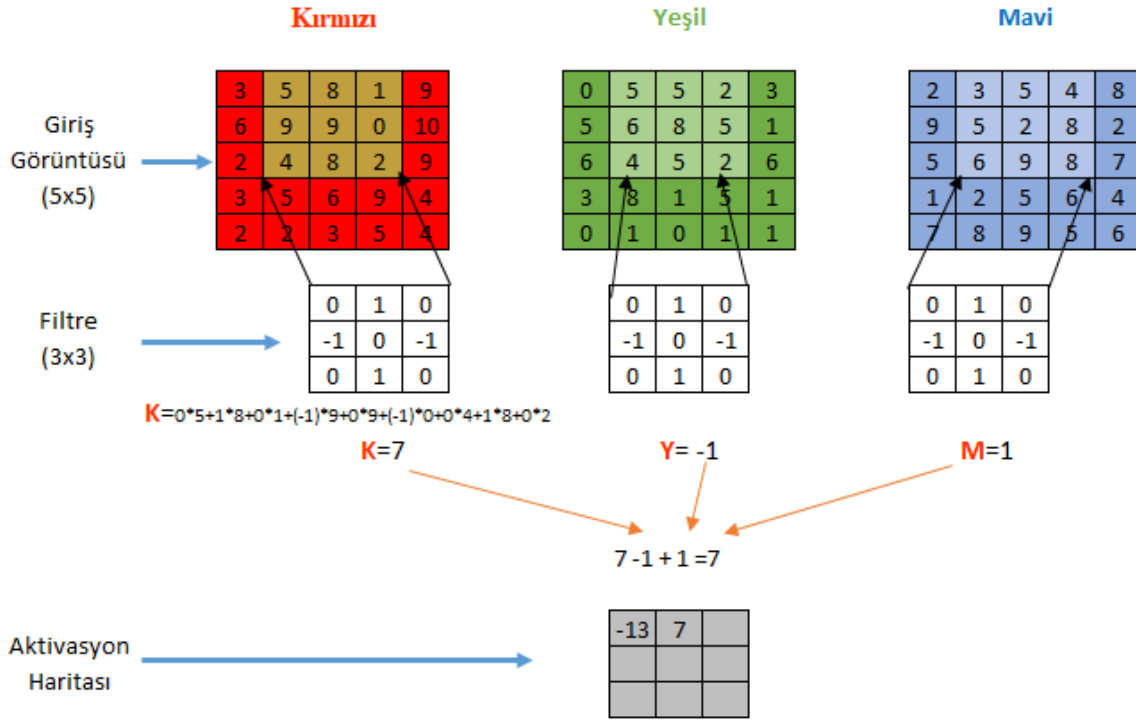
### 2.3.1. Giriş Katmanı

Veri giriş katmanı olarak bilinen bu katman, evrişimsel sinir ağına görüntü verilerinin ilk gönderildiği katmandır. Giriş katmanına “Genişlik x Yükseklik x Kanal” şeklinde 3 boyutlu bir matris olarak verilen RGB görüntüsü, ağın eğitimi için girdi verisi olarak kullanılır. Her bir görüntüye ait veri art arda gelerek bir veri setini oluşturur. Burada veri setinin boyutu, ağın test süresi ve bellek ihtiyacı ile doğru orantılı olarak artıp azalacaktır. Düşük boyutlu bir görüntü verisi bellek ihtiyacı ve eğitim sürecini azaltırken oluşturulacak ağın derinliğini azaltır bu da performansı düşürebilir. Bu sebeple görüntü analizlerinde hem ağ derinliği hem donanımsal maliyet hem de ağın başarısı için uygun bir giriş görüntüsü boyutu seçilmelidir (İnik ve Ülker, 2017).

### 2.3.2. Konvolüsyon (Evrişim) Katmanı

Konvolüsyonel sinir ağlarının temelini oluşturan bu katmanda girdi verisi üzerine önceden belirlenmiş bir filtre uygulanarak girdi verisinin belirgin özellikleri elde edilir. Filtreleme işlemi sonucunda girdi verisinden daha küçük boyutlu bir matris verisi oluşturulur.

Evrişim (konvolüsyon) işleminde, önceden belirlenen “n x n” boyutlu filtreleme matrisi girdi görüntüsüne ait görüntü matrisi üzerinde adım adım gezdirilir. Her bir adımda giriş matrisi ile filtreleme matrisinin çakıştığı değerler çarpılıp varsa diğer kanallardan da aynı şekilde gelen değerler ile toplanarak yeni bir matrisi oluştururlar. Elde edilen bu yeni matris giriş görüntü veri matrisine göre daha küçük boyutta oluşmaktadır. Bu şekilde evrişim işlemi tamamlanarak giriş verisine ait belirgin özellikler elde edilmiş olur. Şekil 2.3’de 5x5x3 boyutlu bir girdi verisinin 3x3 boyutlu bir filtre maskesi ile olan konvolüsyon işlemi gösterilmektedir.



Şekil 2.3. 5x5x3 boyutlu görüntünün 3x3 boyutlu filtre ile konvolüsyon işlemi (İnik ve Ülker, 2017)

Konvolüsyon işlemi sonrasında elde edilen özellik haritasında, giriş görüntüsü boyutu, filtre boyutu, adım büyüklüğü gibi parametreler yer alır. Yapılan evrişim (konvolüsyon) işleminin matematiksel formülü denklem 1’de gösterilmiştir (Karadeniz, 2023).

$$(f * g)(t) = \int_{-\infty}^w f(\tau)g(t - \tau)dt \quad (1)$$

Formüldeki  $f$  giriş görüntüsünü  $g$  ise filtreyi ifade etmektedir.


Uygulanan filtreler, her bir derin öğrenme algoritmasında aynı olabileceği gibi farklı boyutlarda da olabilmektedir. Örneğin AlexNet mimaride  $11 \times 11$  matrisle filtreleme yapılırken ZfNet mimaride  $7 \times 7$  matrisle filtreleme yapılmaktadır. Yine yaygın olarak kullanılan GoogleNet, VGGNet, ResNet mimarilerde  $5 \times 5, 3 \times 3, 2 \times 2, 1 \times 1$  boyutlu filtrelemeler ile konvolüsyon işlemi yapılabilmektedir (Doğan ve Türkoğlu, 2019).

### 2.3.3. Aktivasyon Katmanı

Evrışimli sinir ağlarında aktivasyon katmanı, genellikle evrişim katmanının ardından gelir ve temel amacı evrişim katmanından gelen sonuçları daha anlamlı ve yorumlanabilir hale getirmektir. Bu şekilde ağın öğrenme yeteneği daha da artırılmış olmaktadır. ReLU (Rectified Linear Unit), Sigmoid ve Tanh aktivasyon fonksiyonları, diğer aktivasyon fonksiyonlarına oranla daha hızlı olmasından dolayı yaygın olarak kullanılmaktadır (Nair ve Hinton, 2010).

### 2.3.4. Tam Bağlı (Full-Connected) Katman

Evrışimsel sinir ağı modellerinde tam bağlı katman, kendinden önce gelen tüm katmanlara tam bağlıdır. Tam bağlı katmanda önceki katmanlara bağlı olarak özellikler açığa çıkar. Ortaya çıkan bu özellikler giriş verisindeki nesnenin hangi sınıfla ilişkili olduğunu belirler. Şekil 2.4' de tam bağlı katman yapısı gösterilmiştir.




Şekil 2.4. Tam bağlı katman yapısı.

### 2.3.5. Havuzlama (Pool) Katmanı

Bu katmanda, bir önceki ReLu (Aktivasyon) katmanından gelen veriler indirgenerek bir sonraki konvolüsyon katmanı için giriş verisinin boyutları azaltılır. Burada yapılan bu işleme aşağı örnekleme de denilmektedir. Aşağı örnekleme işlemi veri üzerinde bir takım kayıplar oluşturur. Bu kayıplar, sonraki katmanlar için işlenecek veri miktarını azaltmış olacağı için ağıın hızlanmasına katkı sağladığı gibi ağıdaki hesaplama ve bellek miktarlarının da azalmasını sağlamaktadır (Hinton ve diğerleri, 2012).

Havuzlama katmanında; uygun boyutlarda bir filtre, veri havuzu içerisine uygulanarak giriş veri matrisleri içinde kalan uygun değerlerin saptanmasını sağlar. Bu en uygun değerlerin saptanmasında Şekil 2.5' de gösterilen en büyük havuzlama (max pooling) ya da ortalama havuzlama (average pooling) yöntemlerinden biri kullanılır. En büyük havuzlama yönteminde giriş verisi üzerinde filtreye karşılık gelen kısımdaki en büyük değer alınırken ortalama havuzlama yönteminde filtreye karşılık gelen kısımdaki değerlerin ortalaması hesaplanır (Karadeniz, 2023).



Şekil 2.5. En büyük havuzlama (max pooling) örneği.

Evrişimsel sinir ağlarında havuzlama katmanı her mimaride yer almayabilir. Havuzlama katmanı sonucunda elde edilen görüntünün boyutu aşağıdaki gibi hesaplanır (İnik ve Ülker, 2017).

$$\text{Üretilen Yeni Görüntü Boyutu} = G_2 \times Y_2 \times D_2 \quad (2)$$

$$G_2 = \frac{(G_1 - F)}{A} + 1 \quad (3)$$

$$Y_2 = \frac{(Y_1 - F)}{A} + 1 \quad (4)$$

$$D_2 = D_1 \quad (5)$$

$G_1$	→	Giriş verisi buyutunun genişlik değeri
$G_2$	→	Giriş verisi buyutunun yükseklik değeri
$D_1$	→	Giriş verisi buyutunun derinlik değeri
$F$	→	Filtrenin boyutu
$A$	→	Adım sayısı

Havuzlama işlemi yapılırken genelde  $F$  değeri 2 ve  $A$  değeri 2 olarak alınır. Havuzlama katmanında derinlik aynı kalmaktadır.

### 2.3.6. Softmax Katmanı

Evrışimsel sinir ağlarında sınıflandırma işlemi yapılırken girdi görüntü verisi tüm katmanlardan geçirilerek son kısımda sınıflandırma tahmininin yapılması için softmax katmanına iletilir. Softmax sınıflandırıcı katmanı nesnenin çıkıştaki hangi sınıfa ait olabileceğini değerlendirerek 0 ile 1 arasında bir değer üretir. Burada elde edilen değerlerin 1'e yakın olması doğru sınıflandırma olasılığını artırmaktadır (Doğan ve Türkoğlu, 2019).

### 2.3.7. Diğer Katman ve Kavramlar

Konvolüsyonel sinir ağlarını yapısında bazı temel katmanlarla birlikte pek çok gizli katman yer almaktadır. Evrışimsel sinir ağları, model başarısının artırılarak yüksek doğruluk oranına sahip sınıflandırmalar yapabilmesi için bazı hiper-parametreler kullanmaktadır. Aktivasyon katmanı, öğrenme katsayısı, filtre boyutu, giriş görüntüsü boyutu, seyreltme,

katman sayısı, mini-batch size, epoch parametreler evrişimsel sinir ağlarının eğitilmesinde kullanılan kavramlardan bazılarıdır (Karadeniz, 2023).

### Mini-Batch Değeri

Evrişimsel sinir ağları eğitilirken tüm verilerin aynı anda işleme alınması, donanım ya da hesaplama açısından oldukça maliyetli olacağı için söz konusu değildir. Dolayısıyla veri seti tamamı yerine parça parça alınarak eğitim aşamasına alınmaktadır. Aynı anda eğitime alınacak veri miktarı  $2^n$  sayıdaki mini-batch değeri ile belirlenir (Du, Shen, Liu, Lu, ve Gong, 2021). Mini-batch değerinin yüksek tutulması donanım ve bellek maliyetini artıracaktır.

Mini-batch değeri, modelin eğitilmesi esnasında tüm veri setinin küçük parçalara (mini-batch) bölünmesini ifade eder. Doğru seçilmiş bir mini-batch değeri bilhassa yüksek miktardan oluşan veri setleri ile çalışıldığında verimlilik ve hız açısından avantaj sağlamaktadır. Mini-batch değeri aynı zamanda model eğitiminin her bir iterasyonunda kullanılacak görüntü sayısı olarak ifade edilmektedir.

### Epoch Değeri

Evrişimsel sinir ağları eğitilirken aynı anda verilerin tamamı eğitime alınmazlar. Bunun yerine belli miktarda parçalar halinde alınarak eğitime alınırlar. Eğitim veri setinin tamamının model tarafından bir kez eğitime alınması ile tekrarlanan bu eğitim adımlarının her birine 1 epoch denilmektedir. Her bir parça eğitildikten sonra elde edilen başarımlar, geriyayılım (backpropagation) ile modelin ağırlıklarını günceller. Her yeni parça eğitildiğinde bu işlemler tekrarlanarak modelde ağırlıklar güncellenir ve en uygun ağırlık değeri elde edilmeye çalışılır (Gürbüz, 2020).


## **2.4. Faster R-CNN**

Evrişimsel sinir ağları ile bir görüntü üzerindeki herhangi bir nesnenin tahmin edilmesi, görüntünün sınıflandırılması işlemidir. Nesnenin görüntü üzerindeki konumu ya da nesnenin görüntüde kapladığı sınırların belirlenmesi ise nesne tanımlama işlemidir. Nesne algılama (Object Detection), görüntü üzerindeki ilgilenilen nesnelerin algılandığı bir görme teknolojidir.



Şekil 2.6. Görüntü sınıflandırma ile nesne algılama arasındaki fark

Bir yapay zekâ modeli, Şekil 2.6’da soldaki gibi görüntünün hastalıklı bir yaprağa ait olduğunu belirleyecekse yaptığı iş sınıflandırma, görüntüyü hastalıklı yaprak olarak sınıflandırırken (sağda) aynı zamanda hastalık belirtisinin konumunu da belirliyorsa yaptığı iş nesne algılamadır. Derin öğrenmede nesne tanımlama için R-CNN modeli tasarlanmıştır (Girshick, Donahue, Darrell, ve Malik, 2014).




Şekil 2.7. R-CNN mimarisi.

R-CNN mimarisi, Şekil 2.7.’de görüldüğü üzere 4 ana kısımdan oluşmaktadır. İlk kısımda görüntüler alınırken ikinci kısımda görüntü üzerinde Seçici Arama(SA) ile konum ya da bölge önerileri çıkarılır. Önerilen kısımlar üçüncü bölümde ön eğitilmiş bir ESA modeline verilir. Dördüncü bölümde ise ESA’dan gelen her bir çıktı sınıflara ayrıştırılır. Burada seçici arama ile bir görüntüden yaklaşık 2000 farklı bölge önerisi çıkarılıp bunların her biri üçüncü bölümde ESA ya verilmektedir. Her bir girdi görüntüsünden elde edilen çok sayıdaki bölge

önerisi ESA'nın eğitim aşamasında çok zaman kaybına neden olacaktır. Bu sorunu çözmek için Fast R-CNN modeli önerilmiştir (Girshick, 2015).

Fast R-CNN modelde, R-CNN'den farklı olarak seçici aramadan gelen her bir bölge önerisi yerine girdi görüntüsünün tamamına CNN uygulanır. CNN'den elde edilen özellik haritasına göre bölge önerisi oluşturulur. Bu yöntem test ve eğitim süresini önemli ölçüde kısaltmıştır (PseudoLab, 2020).



Şekil 2.8. Faster R-CNN mimarisi.

Faster R-CNN modelinde, CNN bir bölge öneri modeli (RPN) ile birlikte kullanılarak nesne algılama yapmaktadır. Girdi görüntüsündeki her bir konumda algıladığı nesne sınırlarını ve nesnellik puanlarını aynı anda tahminleyen bir evrişimli ağ modelidir. Bu modelde Fast R-

CNN ve RPN modelleri tüm evrimsel özelliklerini paylaşmak üzere tek bir ağda birleştirilmiştir. Faster R-CNN yapısında iki ana modül yer almaktadır. İlk modül, bölge önerileri sunan bir ESA'dan oluşmaktadır. İkinci modül ise ilk modülde önerilen bölgeleri kullanan hızlı R-CNN yapısıdır (Faster, 2015). Şekil 2.8.'de iki ana modülden oluşan Faster R-CNN modeli gösterilmiştir.

R-CNN, Fast R-CNN ve Faster R-CNN mimari modelleri ile ayrı ayrı Pascal Voc veri seti üzerinde yapılan deneysel çalışmaların sonuçları Çizelge 2.1.'de verilmiştir (İnik ve Ülker, 2017).

Çizelge 2.1 R-CNN, Fast R-CNN ve Faster R-CNN modellerin performans karşılaştırması

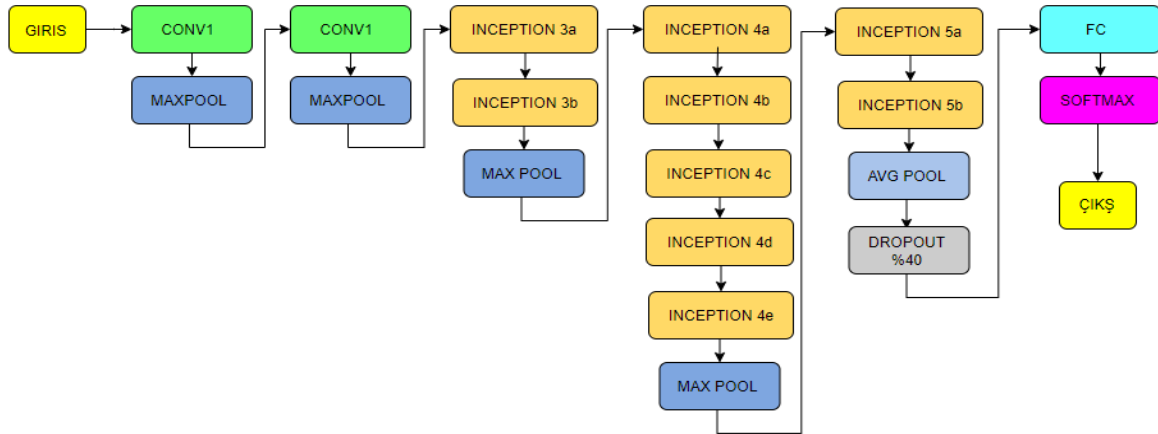
Ölçüt	R-CNN	Fast R-CNN	Faster R-CNN
Görüntü test süresi(sn)	50	2	0.2
Hız	1x	25x	250x
Yüzdesel Tahmin	66	66.9	66.9

## 2.5. Ön Eğitimli Evrimsel Sinir Ağı Modelleri

Ön eğitimli derin öğrenme modelleri, daha önce geniş veri kümeleri üzerinde eğitilmiş ve belirli bir görevi öğrenmiş modellerdir. Bu modeller, transfer öğrenme yöntemleriyle başka görevler için yeniden kullanılabilir. Bu yöntem, sıfırdan bir model eğitmekten daha az zaman ve hesaplama kaynağı gerektirir ve genellikle daha iyi performans sağlar (Han ve diğerleri, 2021).

### 2.5.1. GoogleNet

GoogleNet (Inception) mimarisi, 2014 yılında düzenlenen ILSVRC yarışmasında %5,7 gibi düşük bir hata oranı ile iyi bir başarı elde ederek birinci olmuştur. 22 katman derinliğe sahip olan GoogleNet ağında toplam 144 katman yer almaktadır. Inception modülü ile farklı boyutlarda filtrelemeler yapabilen GoogleNet ağı diğer mimarilere göre farklılık göstermektedir. Şekil 2.9' da GoogleNet mimari yapısı gösterilmiştir.



Şekil 2.9. GoogleNet Mimarisi (Kaya).


Inception modülü sayesinde GoogleNet mimarisinde farklı boyutlarda filtrelemeler yapılabilmektedir. AlexNet'e göre 12 kat daha az parametre içeren bu mimaride 1x1, 3x3, 5x5 şeklinde farklı filtrelemeler yapılabilmektedir. GoogleNet mimarisi, diğer mimarilerdeki art arda katmanlardan oluşmuş yapıdan farklı olarak geliştirdiği modüler filtreleme yapısı sayesinde daha derinlikli bir yapıdadır (Doğan ve Türkoğlu, 2019).

GoogleNet mimarisinde, tam bağlantılı katmanların (full connected) sayısını azaltmak için modelin son katmanlarında global average pooling kullanılmıştır. Average pooling kullanımı modelin genelleme kabiliyetini artırmaktadır. Modelin ara katmanlarında yer alan ek sınıflandırıcılar sayesinde modelin derin kısımlarında bile gradyanların etkili bir biçimde geri yayılımı dolayısı ile eğitimin de daha stabilize olması sağlamıştır. Düşük hata oranları, diğer derin ağlara göre daha az parametre içermesi neticesinde düşük bellek gereksinimi, yapısındaki inception modülü sayesinde farklı veri kümelerinde etkili öğrenme yeteneği GoogleNet modelin avantajlı yönleri olarak öne çıkmaktadır. Diğer basit ağlara göre inception modüllerindeki yapısal karmaşıklık ile büyük ağ derinliğinin getirdiği yüksek hesaplama gücüne olan gereksinim GoogleNet modelin dezavantajları olarak ön plana çıkmaktadır (Krizhevsky, Sutskever, ve Hinton, 2021).

### 2.5.2. AlexNet

AlexNet ESA modeli 2012 yılında düzenlenen ImageNet yarışmasında görüntü tanımada hata oranını %26 seviyelerinden %15 seviyesine indirmiş ve birinci olmuştur. AlexNet modelinde doğrusal olmayan fonksiyonlar için Aktivasyon (Relu) katmanı, eğitim sürecinde

aşırı öğrenmeyi engellemek için Bırakma (dropout) katmanı ve ağırlık gecikmeleri ve momentum değerleri için ise Gradyan iniş modeli kullanılmıştır. Bu mimaride 5 temel konvolüsyon katmanı yer almaktadır. Her konvolüsyon katmanından sonra bir aktivasyon (Relu) katmanının bulunduğu bu mimari, giriş katmanı, normalizasyon katmanı, havuzlama katmanı, dropout katmanı, tam bağlı katman ve çıkış katmanından oluşmaktadır (Doğan ve Türkoğlu, 2019). Şekil 2.10' da AlexNet mimari yapısı gösterilmiştir.



Şekil 2.10. AlexNet Mimarisi Yapısı.

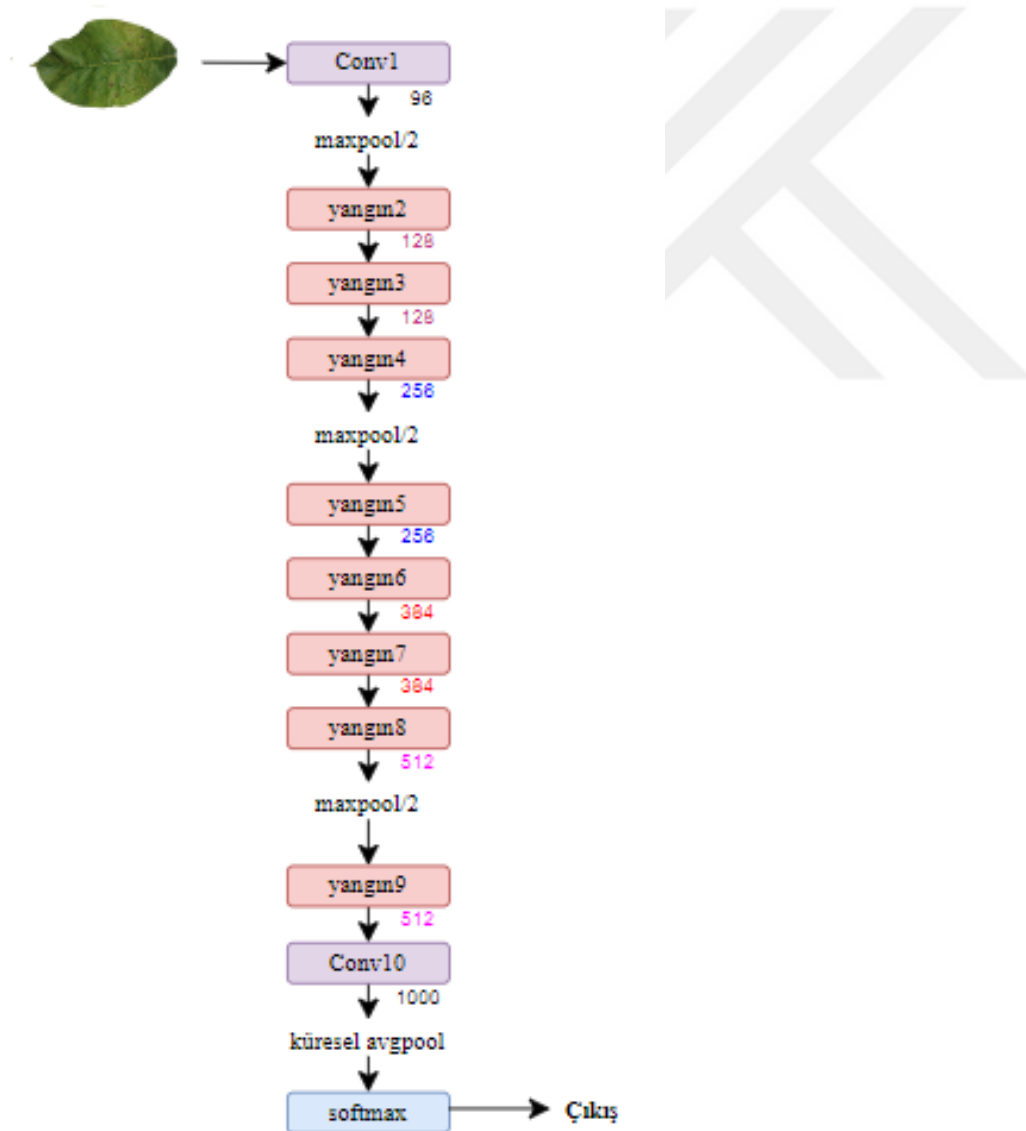
Şekil 2.10'daki çok katmanlı AlexNet mimaride görüldüğü gibi her katman işlevinden sonra veriler sonraki katmana aktarılmaktadır. Giriş katmanından itibaren her katman arasında aktarılan ve işlenen veri miktarı oldukça fazladır. Normal bir bilgisayar işlemcisi ile çok fazla zaman alan bu işlemleri kısaltmak için aynı anda çok daha fazla işlem yapabilen GPU işlemcileri kullanılmaktadır (Krizhevsky ve diğerleri, 2021).

### 2.5.3. SqueezeNet

SqueezeNet, AlexNet düzeyinde doğruluk sağlayabilen fakat AlexNet'e göre çok daha az parametre kullanan aynı zamanda küçük boyutu ile ön plana çıkmış bir evrimsel sinir ağı modelidir. Ortaya çıkış amacı, diğer sinir ağları ile aynı doğruluk seviyesini daha az parametre, donanım ve depolama alanı ile elde etmektir. SqueezeNet ağı ile ImageNet üzerinde yapılan çalışmada AlexNet ile elde edilen doğruluk oranı 50 kat daha az parametre ile elde edilmiştir. Daha az parametre ve donanım maliyeti ile tasarlanmış olması sequezenet modelinin mobil cihazlar ya da gömülü sistemler gibi sınırlı hesaplama

donanımına sahip cihazlarda tercih edilmesine neden olmaktadır (Iandola ve diğerleri, 2016).

SqueezeNet modelindeki en önemli unsur yapısında yer alan Fire modülüdür. Fire modülü kendi içerisinde squeeze ve expend katmanları olmak üzere 2 ana katmandan oluşur. Squeeze katmanı, giriş kanal sayısını azaltan 1x1 evrişim filtrelerinden oluşmaktadır. Expend katmanında ise hem 1x1 hem de 3x3 evrişim filtreleri yer almaktadır. Expend katmanındaki bu filtreler squeeze katmanının çıktısını genişletmek için kullanılmaktadır (Iandola ve diğerleri, 2016). Şekil 2.14’ de SqueezeNet mimari yapısı gösterilmiştir.



Şekil 2.14. SqueezeNet makro mimari görünümü (Iandola ve diğerleri, 2016).

## 2.6. Performans Metrikleri

Derin öğrenme algoritmaları ile gerçekleştirilen nesne tespiti ve sınıflandırma işlemlerinin başarımlarının değerlendirilmesinde karışıklık matrisi (Confusion Matrix) önemli bir ölçüttür. Karışıklık matrisinde, gerçek değer ve tahmin edilen değerlerden oluşan 4 farklı kombinasyona ait sonuçlar gösterilir.

		GERÇEK DEĞER	
		Pozitif (1)	Negatif (0)
TAHMİN EDİLEN DEĞER	Pozitif (1)	TP	FP
	Negatif (0)	FN	TN

Şekil 2.15. Karışıklık matrisi (Confusion matrix)

- TP (True Positive – Doğru Pozitif) : Gerçekte pozitif olan ve sınıflandırıcının da pozitif olarak tahmin ettiği örnek sayısını ifade eder.
- FP (False Positive– Yanlış Pozitif) : Gerçekte negatif olan ve sınıflandırıcının pozitif olarak tahmin ettiği örnek sayısını ifade eder.
- TN (True Negative – Doğru Negatif) : Gerçekte negatif olan ve sınıflandırıcının da negatif olarak tahmin ettiği örnek sayısını ifade eder.
- FN (False Negative– Yanlış Negatif) : Gerçekte pozitif olan ve sınıflandırıcının negatif olarak tahmin ettiği örnek sayısını ifade eder.

### Doğruluk (Accuracy)

Veri setinde doğru tahmin edilen değerlerin sayısının veri setindeki tüm örnek sayısına bölümü ile elde edilir.

$$\text{Doğruluk} = \frac{\text{Doğru Tahmin Sayısı}}{\text{Tüm Örnek Sayısı}} = \frac{TP + TN}{\text{Toplam}} \quad (6)$$

### Duyarlılık (Recall)

Veri setindeki hasta olan yaprakların doğru tespit edilmesi oranıdır denilebilir (Simsek, 2018).

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (7)$$

### Kesinlik (Precision)

Veri setindeki hasta olmayan yaprakların doğru tespit edilmesi oranıdır denilebilir (Simsek, 2018).

$$\text{Duyarlılık} = \frac{TP}{TP + FP} \quad (8)$$

### F1 - Skor (F1-Score)

Kesinlik ve duyarlılık değerlerinin harmonik ortalaması olarak ifade edilir (Simsek, 2018).

$$F1 - \text{Skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (9)$$

### 3. CEVİZ HASTALIKLARI VE BESİN YETERSİZLİĞİ

Ceviz, dünyada ve ülkemizin birçok bölgesinde gerek kereste gerekse de yemiş olarak üretimi yapılan ve birçok insanın geçimini sağlayan önemli bir bitkidir. Ülkemizde ceviz üretimi 1970’li yıllarda dünyada en ön sırada iken 2000’li yıllar itibari ile iyice gerilemiş ve hatta üretilen ceviz miktarı ülkemiz ihtiyacını karşılayamaz duruma gelmiştir (Aslansoy, 2012). Bu gerilemenin bir sebebi de zararlı organizmaların üretime verdiği zarlardır.

Bitkilerde karşılaşılan olası hastalıklar yaygın olarak bitki organlarına ya da bitki patojeni organizma gruplarına göre sınıflandırılır. Bazı patojenler bitkinin birden çok organında hastalığa dair belirtiler oluşturmaktadır. Bu durumlarda ise yaygın olarak belirti gösterdiği organ dikkate alınmaktadır.

Armillaria kök çürüklüğü, Phytophthora kök ve kök boğazı çürüklükleri ile gövde ve dal kanserleri, Geriye doğru ölüme neden olan patojenler, Dal solgunluğu, Pamuğumsu Kök çürüklüğü hastalıkları kök ve gövde hastalıkları olarak sıralanabilir. Kök kanseri ile Derin veya yüzeysel kabuk kanseri ise bakteriyel kaynaklı hastalıklar olarak sınıflandırılabilir (Tezcan, 2005).

#### 3.1. Ceviz Yaprak Hastalıkları

Ceviz antraknozu, Microstroma beyaz küfü, Boğa gözü yaprak lekesi, Alternaria yaprak lekesi, Ascochyta halkalı lekesi gibi hastalıklar ceviz yapraklarında karşılaşılan fungal kaynaklı hastalıklar olarak ifade edilebilirken ceviz yanıklığı ise bakteriyel kaynaklı tek yaprak hastalığı olarak öne çıkmaktadır (Tezcan, 2005).

##### 3.1.1. Ceviz Antraknozu

Ceviz antraknozu Gnomonia leptostyla hastalığı en yaygın rastlanan hastalık etmenidir (Zeki ve Özdem, 2013). Ceviz antraknozu, dünyada ve yurdumuzda ceviz ağacının en önemli hastalıklarından biridir ve genellikle çok yağışlı geçen ilkbahar ayları ile az yağışlı geçen yaz aylarında önemli düzeyde ekonomik zararlar oluşturmaktadır Gnomonia leptostyla hastalığı belirtileri genellikle ağacın yaprağında, meyvesinde ve genç sürgünlerinde tespit

edilmiştir. Hastalıklı yapraklarda enfeksiyon noktasının çevresi sarımsı bir renk almaktadır. Ayrıca gerekli mücadelenin yapılmadığı bölgelerde hastalık ilerledikçe ağaç çıplak bir hal alarak ağaçta kurumalar meydana gelmiştir (Gökçe, Turak, Albayrak, ve Akbaş, 2011). Bununla beraber hastalığa yoğun şekilde yakalanan yapraklar genellikle vaktinden önce dökülerek dalların iyi olgunlaşmamasına neden olmakta ve kışın da dona karşı hassasiyetinin artmasına neden olmaktadır (Bremer, 1954). Ceviz antraknozu belirtisi olan ceviz yaprağı Resim 3.1’ de verilmiştir.



Resim 3.1. Ceviz Antraknozu

Cevizlerde antraknoz etmeni *Gnomonia leptostyla* yapraklarda kahve renkli lekelerle başlamaktadır. Bu lekeler birleşerek yaprağın tamamını kaplamakta ve devamında oluşacak şiddetli enfeksiyonlarda ağacın kavrulmuş görünümü ortaya çıkmaktadır (Eken ve Demirci, 1998). Hastalık genellikle oransal olarak nemi yüksek olan bölgelerdeki genç sürgün ceviz yapraklarında, meyvelerinde ya da yaprak saplarında görülmektedir. Hastalığın belirtileri yapraklarda ve ceviz kabuğunda küçük lekelerin oluşmasıdır. Bu lekeler büyüyüp birleşerek tüm ceviz ya da yaprak yüzeyini kaplayabilmektedir. Bu durum zamanla yeşil renkteki ceviz kabuğuna da zarar vererek verimde kayıplara neden olmaktadır (Budak, 2010). Hastalığın şiddetlenmesi neticesinde yapraklar tamamen dökülerek sürgünlerde kurumalar meydana gelmektedir (Gökçe ve diğerleri, 2011).

### 3.2. Cevizde Besin Yetersizliği

Bitkiler, ihtiyacı olan besin elementlerini yaprakları aracılığı ile havadan, kökleri ile de topraktan alır. Topraktan yada havadan alınan besin miktarı yeterli olmadığı durumlarda da gübrelemeye ihtiyaç duyarlar. Bitkilerin gelişmesi ve iyi bir verim elde edilebilmesi için

bitkinin yeteri miktarda makroelement ve mikroelementleri alması gerekmektedir. Ceviz yetiştirilği kapsamında da ceviz fidanlarının ve ağaçlarının gerek makroelementlere (Azot (N), Fosfor (P), Potasyum (K), Kalsiyum (Ca), Magnezyum (Mg), Kükürt (S), Sodyum (Na)) gerekse de mikroelementlere (Bor (B), Demir (Fe), Bakır (Cu), Çinko (Zn), Mangan (Mn), Molibden (Mo), Nikel (Ni), Klor (Cl) ve Selenyum (Se)) ihtiyacı olmaktadır. Ceviz, elementlerin bir kısmına çok fazla duyarlılık göstermektedir. Bu maddelerin eksikliği ceviz ağacının gelişimini ve ceviz meyvesinin oluşumunu olumsuz etkilemektedir. Ceviz bitkisinde bu elementlerin eksikliğini tespit etmenin en iyi yolu da yaprak analizidir. Bazı makroelement ve mikroelement eksiklikleri yaprak analizinde birbirine benzeyebilmekte ve uzmanlık gerektirmektedir. Şüphelenilen durumlarda ise ceviz ağacından alınacak yeterli miktardaki yaprağın toplanarak bir laboratuvarlarda analizi yaptırılmalıdır (*Cevizde Besin Elementi Eksiklikleri*, 2016).

### 3.2.1. Ceviz Bitkisinde Bor(B) Eksikliği

Bir ceviz ağacındaki besin eksikliği belirtilerini yapraklarından da anlamak mümkündür. Örneğin Resim 3.2' de görüldüğü üzere yaprak yüzeyindeki açık renkli lekeler ve benekli yeşil renkli açılmalar cevizde Bor (B) eksikliğinin tipik bir belirtisidir (Yıldıran, 2013).



Resim 3.2. Bor elementi eksikliği görülen ceviz yaprağı

### 3.2.2. Ceviz Bitkisinde Demir (Fe) Eksikliği

Toprağın pH değerinin yüksek olması ve topraktaki element fakirliği demir eksikliğinin ana nedenidir. Demir eksikliği, yaprak yüzeyinin ve yeni sürgün yaprakların renginin tamamen

açık sarıya dönmesi ile görsel olarak ta anlaşılabilir (Yıldıran, 2013). Resim 3.3' de demir eksikliği belirtisi olan ceviz yaprağı görüntüsü verilmiştir.



Resim 3.3. Demir eksikliği olan ceviz yaprağı görüntüsü

### 3.2.3. Ceviz Bitkisinde Magnezyum (Mg) Eksikliği

Magnezyum elementi ceviz yapraklarına yeşil rengi veren klorofil maddesinin oluşumunu sağlar. Magnezyum elementinin eksikliği bitkide fotosentezi olumsuz etkileyerek ağacın enerji almasını dolayısı ile de gelişim hızını önemli ölçüde azaltır (*Cevizde Besin Elementi Eksiklikleri*, 2016). Topraktaki kireç eksikliği ve pH değerinin yüksek olmasından kaynaklı magnezyum eksikliğinde Resim 3.4' de görüldüğü üzere yaprak sap kısmından başlayarak sararmaya başlaması ve açık renkli bir yapıda yaprağın kuruması cevizde magnezyum eksikliğinin tipik bir belirtisidir (Yıldıran, 2013).



Resim 3.4. Magnezyum eksikliği olan ceviz yaprağı görüntüsü

### 3.2.4. Ceviz Bitkisinde Potasyum (K) Eksikliği

Potasyum, ağacın hastalık ve zararlılara karşı direncini artıran önemli bir makroelementtir. Ağacın su dengesinin korunması noktasında da önemli görevi vardır. Yetersizliğinde ise dokularındaki suyun azalmasıyla beraber ağacın büyümesi de yavaşlayacaktır. Sürgün gelişimi, verim ve kalitede düşüklüğe sebebiyet vermektedir. Ağacın potasyum dengesinin yeterli olması neticesinde dolgun ceviz üretmek mümkün olmaktadır (*Cevizde Besin Elementi Eksiklikleri*, 2016).

Ceviz ağacında potasyum eksikliği, ceviz yaprağının Resim 3.5' de görüldüğü gibi kenarındaki kurumalardan da anlaşılabilir (Yıldırım, 2013).



Resim 3.5. Potasyum eksikliği olan ceviz yaprağı görüntüsü

## 4. MATERYAL VE YÖNTEM

Ceviz yaprak görüntülerinden, ceviz antraknozu hastalığı ile bazı minereral eksiklikleri derin öğrenme yöntemleri kullanılarak tespit edilip sınıflandırılabilir. Bu tez çalışmasında, elde edilen veri seti kullanılarak bilinen ESA modelleri ile geliştirilen Faster R-CNN modelinin sınıflandırma başarımları karşılaştırılmıştır. Çalışma kapsamında bazı yazılım, donanım ve yöntemler kullanılmıştır. Çalışma kapsamında öncelikle veri seti oluşturulmuş ardından veri setine data augmentation (veri çoğaltma) işlemi uygulanmıştır. Bu bölümde, deneysel çalışmada kullanılan materyal ve yöntemler hakkında gerekli bilgiler yer almaktadır.

### 4.1. Çalışmada Kullanılan Yazılım ve Donanımlar


Veri setindeki görüntülerin çekiminde 48MP etkin piksel, 2x Optik Zoom, F/1.8 ~ F/2.0 diyafram ve maksimum 8000x6000 piksel çözünürlük değerlerine sahip Huawei P30 Lite marka ve model mobil telefon kullanılmıştır.

Derin öğrenme ile nesne tespiti ya da sınıflandırma gibi işlemlerin hızlı ve sorunsuz yapılabilmesi için iyi bir bilgisayara ihtiyaç duyulmaktadır. Derin öğrenme işlemlerinde, grafik işlemciler (GPU), bilgisayar işlemcilerine (CPU) göre çok daha hızlı ve verimli çalışmaktadır.

MATLAB, derin öğrenme çalışmalarının hızlı ve verimli bir şekilde gerçekleştirilebilmesi için yaygın olarak kullanılan bir programlama platformudur. MATLAB ile farklı derin öğrenme modelleri geliştirilebilmekte aynı zamanda bu modellerin eğitimi ve değerlendirilmeleri yapılabilmektedir. Bu tez çalışmasında ceviz yapraklarındaki hastalık ve mineral yetersizliği bulgularının sınıflandırılması için bir model geliştirilmiştir. Geliştirilen ve mevcut mimari modellerin performansları detaylıca analiz edilmiştir. Yapılan deneysel çalışmalarda MATLAB programının 64 bit 2021b versiyonu kullanılmış ve çalışmalar için Intel Core i5-3450 CPU 3.10 GHz işlemci, 16 GB RAM ve NVIDIA GeForce RTX2060 grafik kartına sahip bir bilgisayar tercih edilmiştir.

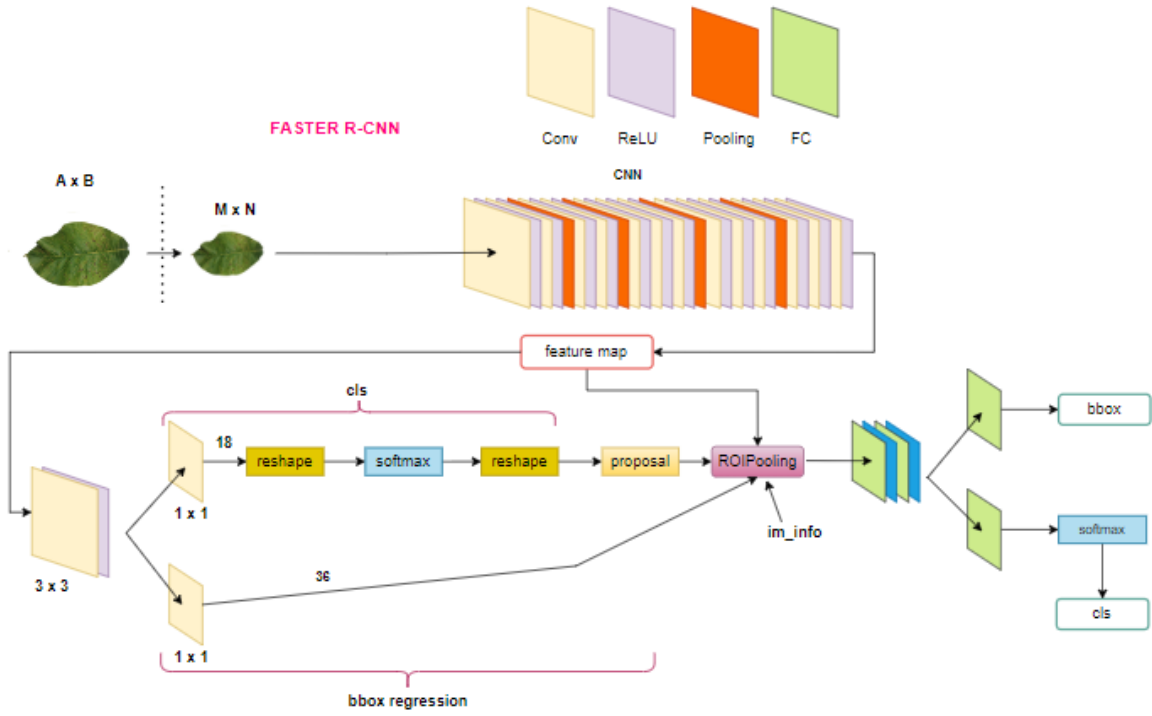
## 4.2. Geliştirilen Yöntem

Geliştirilen yöntemde, Faster R-CNN yapısı ceviz yapraklarında görülen hastalıkların ve vitamin yetersizliklerinin tespiti ve sınıflandırılması için şu şekilde kullanılmıştır: Bu model oluşturulurken, sağlıklı, antraknoz, vitaminsiz ve her iki hastalığa sahip olmak üzere dört sınıflı bir veri seti kullanılmıştır. İlk olarak, girdi görüntüleri konvolüsyonel sinir ağı (CNN) ile işlenerek özellik haritaları çıkarılmıştır. Bu özellik haritaları, Bölge Öneri Ağı (Region Proposal Network - RPN) adı verilen yapı tarafından analiz edilerek olası nesne bölgeleri elde edilmiştir. RPN, çeşitli ölçeklerde ve oranlarda çapa kutuları (anchor boxes) kullanarak bu bölgeleri belirler ve her bölge için nesne veya arka plan olasılıklarını hesaplamaktadır. Şekil 4.1’de geliştirilen yöntemin blok diyagramı görülmektedir.



Şekil 4.1. Geliştirilen Faster R-CNN modelin blok diyagramı

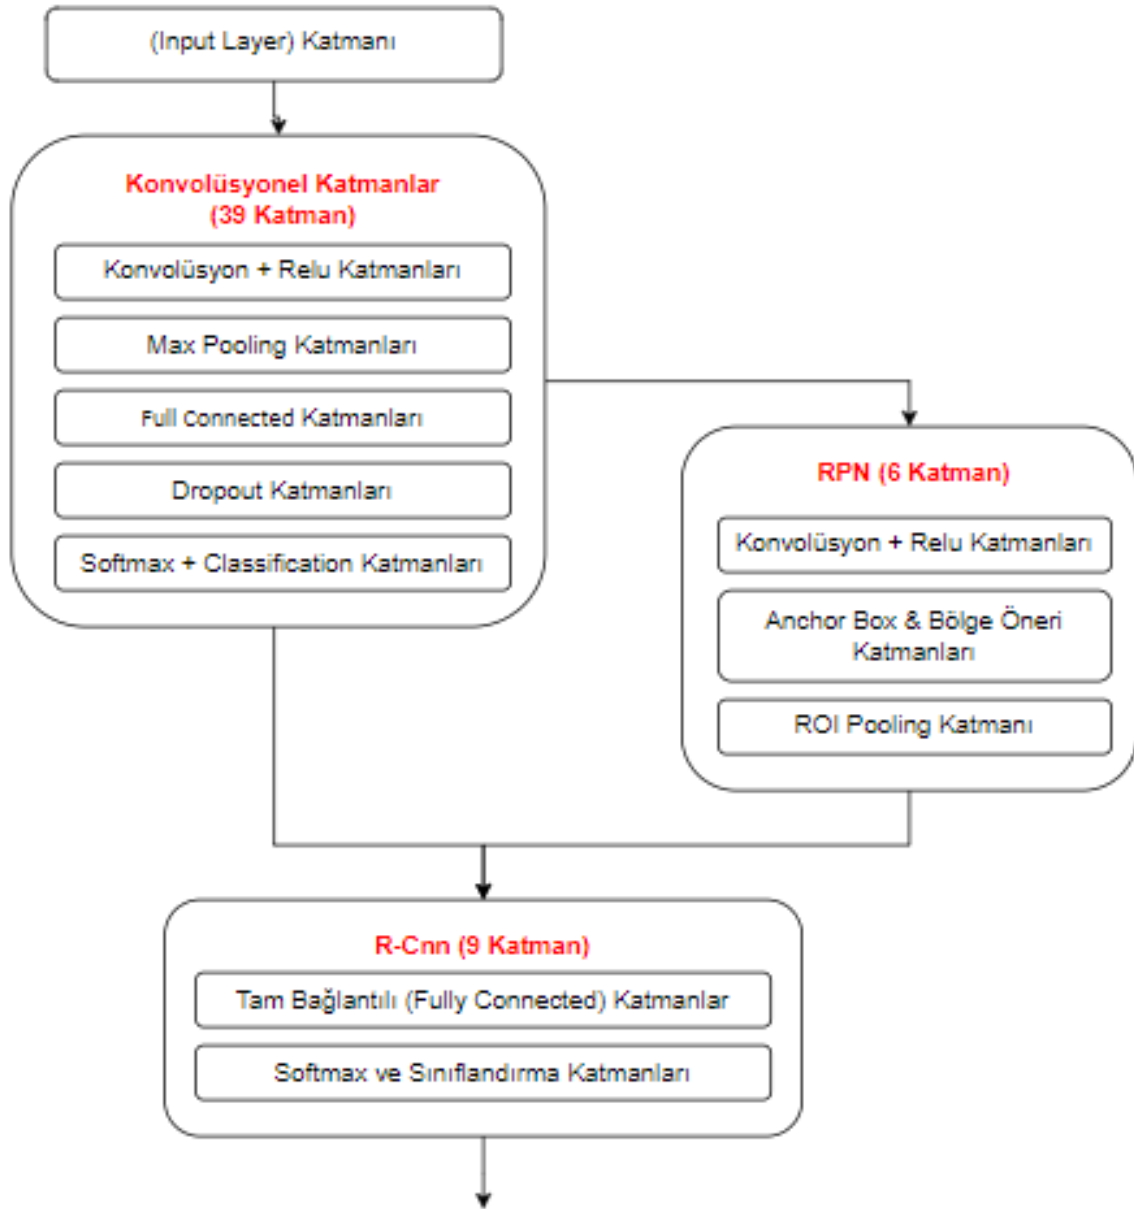
Önerilen bölgeler, ROI Pooling katmanına geçirilerek sabit boyutlara dönüştürülmüş ve tam bağlı katmanlarda dört sınıftan birine (sağlıklı veya üç hastalıktan biri) atanmıştır. Ayrıca, her bölgenin sınır kutusu koordinatları düzeltilmiştir. Son aşamada, “bbox” ile “cls” kutuları arasında Non-Maximum Suppression (NMS) kullanılarak gereksiz veya çakışan öneriler elenmiş ve en güvenilir tespitler elde edilmiştir. Şekil 4.2’de yöntemin detaylandırılmış yapısı gösterilmiştir.



Şekil 4.2. Geliştirilen modelin detaylı gösterimi

Geliştirilen model, görüntülerden oluşan bir veri setinde potansiyel olarak bulunan nesne bölgelerini tespit edip bu bölgeleri sınıflandırmak için tasarlanmış bir Faster R-CNN modelidir.

Model, çeşitli konvolüsyon, ReLU ve havuzlama katmanları ile özellik çıkarımı yaparak RPN katmanları ile bölge önerileri oluşturur ve önerilen bölgeleri ROI Pooling ve tam bağlantılı katmanlar ile sınıflandırır. Geliştirilen Faster R-CNN model, 39 konvolüsyon katmanı, 6 RPN katmanı, 1 ROI Pooling katmanı ve 9 R-CNN katmanı olmak üzere toplam 55 katmandan oluşmaktadır. Şekil 4.3' de geliştirilen Faster R-CNN modelin katmansal yapısı gösterilmiştir.



Şekil 4.3. Geliştirilen Faster R-CNN modelin katmansal yapısı

### 4.3. Veri Seti

Veri seti için gerekli fotoğraflar, Amasya iline bağlı Aydınlık köyünde sonbahar mevsiminde alınmıştır. Fotoğraf çekimi, 8000x6000 çözünürlükte mobil telefon (Huawei P30 Lite) kullanılarak yapılmıştır. Veri seti için 274 adet ceviz yaprağı görüntüsü, ağaçların uç yeni sürgün yerlerinden alınarak fotoğrafları çekildi. Çekilen fotoğraflar bir ziraat mühendisi uzman eşliğinde incelendi. Elde edilen görüntülerde ceviz bitkisinde en yaygın görülen antraknoz hastalığı ile çeşitli vitamin ya da mineral eksikliklerinin olduğu tespit edildi. Uzman eşliğinde sınıflandırma işleminin yapılabilmesi için elde edilen görseller “Sağlıklı”,

“Ceviz Antraknozu (Antraknoz)”, “Mineral Eksikliği (Vitaminsız)”, “Ceviz Antraknozu+Mineral Eksikliği (Her iki hastalık)” olarak 4 sınıfa ayrıştırıldı. Oluşturulan sınıflardan örnek yaprak görselleri Resim 4.1, Resim 4.2, Resim 4.3 ve Resim 4.4’ de gösterilmiştir. Sağlıklı, ceviz antraknozu, mineral eksikliği ve ceviz antraknozu+mineral eksikliği şeklinde oluşturulan sınıflara ait görüntü sayıları sırasıyla 146, 38, 56 ve 34 olarak belirlendi.



Resim 4.1. Sağlıklı örnek yaprak görselleri



Resim 4.2. Ceviz antraknozu (Antraknoz) olan ceviz yaprağı örnekleri




Resim 4.3. Mineral eksikliği (Vitaminsız) olan ceviz yaprağı örnekleri



Resim 4.4. Ceviz antraknozu + mineral eksikliği (Her iki hastalık) olan ceviz yaprağı görselleri

#### 4.4. Veri Büyütme (Data Augmentation)

Farklı eğitim örnekleri elde etmek amacıyla veri seti üzerinde bir dizi değişiklik yapmak veri setini ölçeğini genişletmektedir. Veri çoğaltma (Data augmentation), modelin genelleme yeteneğini artırdığı için derin öğrenmede çok yaygın olarak kullanılmaktadır (Dobrescu, Giuffrida, ve Tsiftaris, 2020).



Şekil 4.4. Data Augmentation uygulanmış ceviz yaprağı örnekleri.

Dört sınıftan oluşan ceviz yaprağı veri setine döndürme, rastgele gürültü, kırpma, öteleme, bulanıklaştırma ve ekleme veri artırma teknikleri uygulanmıştır. Yapılan veri artırma işlemi sonrasında elde edilen görüntü örnekleri şekil 4.4'de, görüntü sayıları ise çizelge 4.1'de gösterilmiştir.

Çizelge 4.1. Veri setindeki görüntü sayılarının sınıflara göre dağılımı

Sınıf	Data Augmentation öncesi görüntü sayıları	Data Augmentation sonrası görüntü sayıları
Sağlıklı	146	2774
Antraknoz	38	780
Vitaminsiz	56	1064
Her iki hastalık	34	627
<b>Toplam</b>	<b>274</b>	<b>5245</b>

#### 4.5. Optimizasyon Algoritmaları

Optimizasyon algoritmaları, derin öğrenmede kayıp fonksiyonlarının en aza indirilerek model parametreleri için en uygun değerlerin elde edilmesi amacıyla kullanılmaktadır. Bu algoritmalar, CNN modellerinin eğitim başarıları ve verimlilikleri açısından önemli bir rol oynamaktadır. SGD, SGDM, Adagrad, RMSProp, Adam, AdaMax, Nadam, AmsGrad ve AdaDelta algoritmaları derin öğrenme modellerinin eğitilmesinde yaygın olarak kullanılmaktadır. Algoritmaların birbirlerine göre belirli avantaj ve dezavantajları vardır. Bu nedenle bir problemin çözümünde en uygun optimizasyon algoritmasının seçilerek hiperparametre ayarlamalarının da dikkatli bir şekilde yapılması gerekmektedir (Goodfellow, Bengio, ve Courville, 2016).

##### SGDM Optimizasyon Algoritması

SGDM (Stochastic Gradient Descent with Momentum), derin öğrenme modellerinin eğitilmesinde kullanılan optimizasyon algoritmalarından biridir. Klasik SGD algoritması, kayıp fonksiyonunu en aza indirmeyi amaçlar. Bu indirmeyi yaparken de bir takım güçlüklerle karşılaşmaktadır. Momentum, bu zorlukların üstesinden gelmeye yardımcı olmaktadır. SGDM optimizasyon algoritması, optimizasyon sürecinin hızlandırılarak daha stabil hale gelmesi için klasik SGD optimizasyon modeline momentum eklenmesi ile elde edilmiştir. Burada momentum, optimizasyon işleminde kendinden önceki adımların yönünü dikkate alarak parametrelerin daha kararlı ve hızlı bir şekilde güncellenmesine olanak sağlar (Goodfellow ve diğerleri, 2016).

## Adam Optimizasyon Algoritması

Adam (Adaptive Moment Estimation), derin öğrenme modellerinin eğitiminde kullanılan SGD optimizasyon algoritmasının bir uzantısıdır. Adam, derin öğrenme modellerinin hızlı ve etkili bir şekilde eğitilebilmesi için adaptif moment tahminlemesi yaparak parametrelerin dinamik olarak optimize edilmesini sağlar. Bu sebele, günümüzde derin öğrenme modellerinin eğitilmesinde Adam algoritması sıklıkla tercih edilmektedir (Goodfellow ve diğerleri, 2016).



## 5. DENEYSEL UYGULAMA

Bu çalışmada ceviz yapraklarında görülen antraknoz ve vitamin yetersizliklerinin tespiti ve sınıflandırılması için Faster R-CNN modeli geliştirilmiştir. Geliştirilen model, Bölüm 4.2'de detaylı olarak anlatılmıştır. Uygulama için öncelikle, 274 adet resimden elde edilen veri seti sağlıklı, antraknozlu, vitaminsiz ve her iki hastalığa sahip olarak sınıflandırılmıştır. Veri setindeki dört sınıfa ait örnek görüntüler resim 5.1'de gösterilmiştir.



Resim 5.1. Sağlıklı, antraknozlu, vitaminsiz ve her iki hastalığa sahip görüntüler

Bu sınıflara ait görüntü sayıları çizelge 5.1'de gösterilmiştir.

Çizelge 5.1. Veri setini oluşturan sınıflar ve görüntü sayıları

Sınıf Adı	Görüntü Sayısı
Sağlıklı	146
Antraknoz	38
Vitaminsiz	56
Her iki hastalık	34

Bu resimler, kullanılacak CNN'in büyük veriyle yüksek doğruluklu sonuçlar elde etmesinden dolayı çeşitli ön işleme işlemlerine tabi tutulmuştur. Bu yöntemlerin ilki veri çoğaltma işlemidir. Resimler, orijinal büyüklükleri korunarak döndürme, öteleme, kırpma,

rastgele gürültü ekleme, renk değiştirme ve bulanıklaştırma teknikleriyle artırılmıştır. Artırma işleminden sonra elde edilen veri seti sayıları Çizelge 4.1’de gösterilmiştir

Veri setindeki resimlere ikinci işlem olarak resim küçültme işlemi uygulanmıştır. Deneysel uygulama için kullanılan donanım mimarisi de düşünülerek 128x128x3 boyutlarına küçültme işlemi gerçekleştirilmiştir. Küçültme işleminde, resimler 128x128x3 boyutlarında bir piksel matrisine standardize edilmiştir. Yeniden boyutlandırma aşamasında, görüntünün kalitesini korumak için antialias özelliği kullanılarak kenar yumuşatma işlemi uygulanmış ve bikübik interpolasyon yöntemi ile pikseller arası geçişler daha pürüzsüz hale getirilerek yüksek kaliteli sonuçlar elde edilmiştir.

Oluşturulan veri setinin testlerine başlayabilmek için, literatür taramasına dayanarak, geliştirilen model için hiperparametre belirleme işlemi yapıldı. Test işleminde seçilen CNN hiperparametreleri çizelge 5.2’de gösterilmiştir.

Çizelge 5.2. Geliştirilen modelin test işleminde seçilen CNN hiperparametreleri

Hiperparametreler	Değeri
Optimizasyon algoritması	Adam, SGDM
Epoch	10,30,50,100
Mini Batch Size (veri Alt kümesi)	64
Öğrenme oranı	0.001
Doğrulama Frekansı	30

Veri setinin %80’i eğitim, %20’si test olarak belirlenmiştir. Geliştirilen yöntem için kullanılan hiperparametreler, AlexNet, GoogleNet ve SqueezeNet gibi bazı ön eğitilmiş derin öğrenme modelleri ile de test edilerek sınıflandırma başarıları karşılaştırılmıştır. Çizelge 5.2’de gösterilen her iki algoritma ve epoch sayısı için sınıflandırma başarıları elde edilmiştir. Elde edilen başarı değerleri ve geliştirilen model ile ön eğitilmiş modellere ait performans metrikleri (doğruluk, duyarlılık, kesinlik ve F1 skoru), 10 epoch sayısı için Çizelge 5.3’de, 30 epoch sayısı için Çizelge 5.4’de, 50 epoch sayısı için Çizelge 5.5’te ve 100 epoch sayısı için Çizelge 5.6’te gösterilmiştir.

Çizelge 5.3. 10 iterasyon değerinde CNN modellerin performans karşılaştırması

Sınıflar	Derin Öğrenme Modeli	Optimizasyon Algoritması	Doğruluk (Accuracy)	Duyarlılık (Recall)	Keskinlik (Precision)	F1 Skoru
Sağlıklı	Geliştirilen CNN Model	Adam	94.57	0.97	0.98	0.97
		SGDM	93.71	0.95	0.96	0.96
	GoogleNet	Adam	94.18	0.98	0.94	0.96
		SGDM	93.61	0.98	0.94	0.96
	SqueezeNet	Adam	71.69	0.93	0.84	0.88
		SGDM	52.91	1.00	0.69	0.69
	AlexNet	Adam	91.90	0.99	0.89	0.94
		SGDM	93.80	0.99	0.91	0.93
Ceviz Antraknozu	Geliştirilen CNN Model	Adam	94.57	0.88	0.97	0.93
		SGDM	93.71	0.92	0.89	0.91
	GoogleNet	Adam	94.18	0.93	0.94	0.94
		SGDM	93.61	0.87	0.96	0.91
	SqueezeNet	Adam	71.69	0.43	0.63	0.51
		SGDM	52.91	-	-	-
	AlexNet	Adam	91.90	0.81	1.00	0.89
		SGDM	93.80	0.88	0.96	0.92
Mineral Eksikliği	Geliştirilen CNN Model	Adam	94.57	0.96	0.85	0.90
		SGDM	93.71	0.92	0.98	0.95
	GoogleNet	Adam	94.18	0.92	0.93	0.92
		SGDM	93.61	0.90	0.93	0.91
	SqueezeNet	Adam	71.69	0.32	0.59	0.42
		SGDM	52.91	-	-	-
	AlexNet	Adam	91.90	0.90	0.95	0.92
		SGDM	93.80	0.87	0.99	0.93
Ceviz Antraknozu ve Mineral Eksikliği	Geliştirilen CNN Model	Adam	94.57	0.89	0.97	0.92
		SGDM	93.71	0.92	0.83	0.87
	GoogleNet	Adam	94.18	0.84	0.96	0.90
		SGDM	93.61	0.88	0.89	0.88
	SqueezeNet	Adam	71.69	0.78	0.47	0.59
		SGDM	52.91	-	-	-
	AlexNet	Adam	91.90	0.80	0.93	0.86
		SGDM	93.80	0.87	0.99	0.93

Çizelge 5.4. 30 iterasyon değerinde CNN modellerin performans karşılaştırması

Sınıflar	Derin Öğrenme Modeli	Optimizasyon Algoritması	Doğruluk (Accuracy)	Duyarlılık (Recall)	Keskinlik (Precision)	F1 Skoru	
Sağlıklı	Geliştirilen CNN Model	Adam	98.28	0.99	0.98	0.99	
		SGDM	97.43	0.99	0.98	0.99	
	GoogleNet	Adam	95.61	0.99	0.95	0.97	
		SGDM	93.61	0.98	0.94	0.96	
	SqueezeNet	Adam	89.70	0.93	0.95	0.94	
		SGDM	79.22	0.98	0.83	0.90	
	AlexNet	Adam	92.09	0.98	0.91	0.94	
		SGDM	92.95	0.98	0.92	0.95	
	Ceviz Antraknozu	Geliştirilen CNN Model	Adam	98.28	0.96	0.99	0.98
			SGDM	97.43	0.98	0.95	0.97
GoogleNet		Adam	95.61	0.90	0.99	0.95	
		SGDM	93.61	0.87	0.96	0.91	
SqueezeNet		Adam	89.70	0.87	0.86	0.86	
		SGDM	79.22	0.62	0.82	0.71	
AlexNet		Adam	92.09	0.83	0.92	0.87	
		SGDM	92.95	0.87	0.97	0.92	
Mineral Eksikliği		Geliştirilen CNN Model	Adam	98.28	0.97	0.99	0.98
			SGDM	97.43	0.94	0.98	0.96
	GoogleNet	Adam	95.61	0.94	0.96	0.95	
		SGDM	93.61	0.90	0.93	0.91	
	SqueezeNet	Adam	89.70	0.89	0.84	0.86	
		SGDM	79.22	0.63	0.72	0.67	
	AlexNet	Adam	92.09	0.87	0.93	0.90	
		SGDM	92.95	0.90	0.92	0.91	
	Ceviz Antraknozu ve Mineral Eksikliği	Geliştirilen CNN Model	Adam	98.28	0.99	0.97	0.98
			SGDM	97.43	0.95	0.97	0.96
GoogleNet		Adam	95.61	0.88	0.96	0.92	
		SGDM	93.61	0.88	0.89	0.88	
SqueezeNet		Adam	89.70	0.82	0.83	0.82	
		SGDM	79.22	0.44	0.62	0.52	
AlexNet		Adam	92.09	0.85	0.96	0.90	
		SGDM	92.95	0.82	0.96	0.89	

Çizelge 5.5. 50 iterasyon değerinde CNN modellerin performans karşılaştırması

Sınıflar	Derin Öğrenme Modeli	Optimizasyon Algoritması	Doğruluk (Accuracy)	Duyarlılık (Recall)	Keskinlik (Precision)	F1 Skoru	
Sağlıklı	Geliştirilen CNN Model	Adam	97.71	0.99	0.98	0.99	
		SGDM	97.90	0.99	0.99	0.99	
	GoogleNet	Adam	96.85	0.99	0.98	0.98	
		SGDM	96.66	0.99	0.97	0.98	
	SqueezeNet	Adam	92.56	0.99	0.91	0.95	
		SGDM	85.99	1.00	0.84	0.91	
	AlexNet	Adam	93.14	0.98	0.91	0.94	
		SGDM	92.85	0.99	0.90	0.95	
	Ceviz Antraknozu	Geliştirilen CNN Model	Adam	97.71	0.95	0.99	0.97
			SGDM	97.90	0.97	0.97	0.97
GoogleNet		Adam	96.85	0.95	0.95	0.95	
		SGDM	96.66	0.94	0.98	0.96	
SqueezeNet		Adam	92.56	0.89	0.95	0.92	
		SGDM	85.99	0.74	0.91	0.82	
AlexNet		Adam	93.14	0.85	0.94	0.90	
		SGDM	92.85	0.87	0.98	0.92	
Mineral Eksikliği		Geliştirilen CNN Model	Adam	97.71	0.97	0.96	0.97
			SGDM	97.90	0.96	0.98	0.97
	GoogleNet	Adam	96.85	0.93	0.98	0.95	
		SGDM	96.66	0.95	0.94	0.95	
	SqueezeNet	Adam	92.56	0.84	0.96	0.90	
		SGDM	85.99	0.75	0.86	0.80	
	AlexNet	Adam	93.14	0.89	0.96	0.92	
		SGDM	92.85	0.83	0.96	0.89	
	Ceviz Antraknozu ve Mineral Eksikliği	Geliştirilen CNN Model	Adam	97.71	0.95	0.98	0.97
			SGDM	97.90	0.98	0.94	0.96
GoogleNet		Adam	96.85	0.96	0.94	0.95	
		SGDM	96.66	0.92	0.97	0.95	
SqueezeNet		Adam	92.56	0.84	0.93	0.88	
		SGDM	85.99	0.58	0.96	0.73	
AlexNet		Adam	93.14	0.87	0.98	0.92	
		SGDM	92.85	0.88	0.95	0.91	

Çizelge 5.6. 100 iterasyon değerinde CNN modellerin performans karşılaştırması

Sınıflar	Derin Öğrenme Modeli	Optimizasyon Algoritması	Doğruluk (Accuracy)	Duyarlılık (Recall)	Keskinlik (Precision)	F1 Skoru
Sağlıklı	Geliştirilen CNN Model	Adam	97.33	0.99	0.98	0.99
		SGDM	97.24	0.99	0.99	0.99
	GoogleNet	Adam	96.66	0.99	0.97	0.98
		SGDM	97.14	0.99	0.97	0.98
	SqueezeNet	Adam	96.57	0.98	0.98	0.98
		SGDM	90.09	0.97	0.90	0.93
	AlexNet	Adam	91.13	0.97	0.90	0.94
		SGDM	95.52	0.99	0.98	0.98
Ceviz Antraknozu	Geliştirilen CNN Model	Adam	97.33	0.97	0.96	0.96
		SGDM	97.24	0.95	0.97	0.96
	GoogleNet	Adam	96.66	0.95	0.93	0.94
		SGDM	97.14	0.94	0.99	0.96
	SqueezeNet	Adam	96.57	0.94	0.92	0.93
		SGDM	90.09	0.87	0.94	0.91
	AlexNet	Adam	91.13	0.87	0.93	0.90
		SGDM	95.52	0.94	0.92	0.93
Mineral Eksikliği	Geliştirilen CNN Model	Adam	97.33	0.93	0.98	0.96
		SGDM	97.24	0.96	0.96	0.96
	GoogleNet	Adam	96.66	0.92	0.99	0.96
		SGDM	97.14	0.96	0.95	0.96
	SqueezeNet	Adam	96.57	0.96	0.95	0.96
		SGDM	90.09	0.84	0.86	0.85
	AlexNet	Adam	91.13	0.86	0.89	0.88
		SGDM	95.52	0.93	0.94	0.93
Ceviz Antraknozu ve Mineral Eksikliği	Geliştirilen CNN Model	Adam	97.33	0.97	0.93	0.95
		SGDM	97.24	0.94	0.93	0.94
	GoogleNet	Adam	96.66	0.94	0.98	0.96
		SGDM	97.14	0.95	0.98	0.97
	SqueezeNet	Adam	96.57	0.94	0.96	0.95
		SGDM	90.09	0.72	0.96	0.82
	AlexNet	Adam	91.13	0.78	0.98	0.87
		SGDM	95.52	0.87	0.92	0.90

Geliştirilen yöntem için en başarılı değer, 30 epoch sayısı ve Adam algoritmasıyla %98,28 olarak bulunmuştur. Bu başarıya ait karışıklık (Confusion) matrisi Şekil 5.1’de gösterilmiştir.

True Class	Antraknoz	150		5	1	96.2%	3.8%		
	Herikihastalık		124	1		99.2%	0.8%		
	Saglikli		2	551	2	99.3%	0.7%		
	VitaminEksikligi	1	2	4	206	96.7%	3.3%		
		99.3%	96.9%	98.2%	98.6%	0.7%	3.1%	1.8%	1.4%
		Predicted Class							
		Antraknoz	Herikihastalık	Saglikli	VitaminEksikligi				


Şekil 5.1. Geliştirilen modele ait 30 epoch ve Adam algoritması için karışıklık matrisi

Şekil 5.1’de gösterilen geliştirilen modele ait karışıklık matrisinde mavi ile gösterilen alanlar gerçekte ve model tahminlemesi sonucunda doğru sınıflandırılanların sayısını vermektedir. Pembe renkli alanlardaki değerler ise gerçekte olmaları gereken sınıflara göre geliştirilen modelin yanlış tahminlediği sayıları vermektedir. Daha açık ifade ile belirtecek olursak geliştirilen Faster R-CNN modeli;

- Gerçekte antroknoz hastalığı olan 6 görselin 5 tanesini sağlıklı, 1 tanesini vitamin eksikliği olarak hatalı tahmin etmiştir.
- Gerçekte her iki hastalığı olan 1 görseli sağlıklı olarak hatalı tahmin etmiştir.
- Gerçekte sağlıklı olan 4 görselin 2 tanesini vitamin eksikliği ve diğer 2 tanesini her iki hastalık olarak hatalı tahmin etmiştir

- Gerçekte vitamin eksikliği olan 7 görselin 1 tanesini antroknöz, 4 tanesini sağlıklı ve 2 tanesini her iki hastalık olarak hatalı tahmin etmiştir.

Geliştirilen modelin 30 epoch ve adam algoritması için accuary-loss grafiği şekil 5.2’de gösterilmiştir.



Şekil 5.2. Geliştirilen model için accuary-loss grafiği

Veri setimizin AlexNet, GoogleNet ve SqueezeNet derin öğrenme modellerine ait en başarılı epoch sayısı ve başarılarını gösteren karışıklık matrisleri şu şekildedir.

AlexNet en iyi başarıyı 100 epoch SDGM optimizasyon algoritmasında yakalamıştır. Şekil 5.3’de bu modele ait karışıklık matrisi gösterilmiştir. Bu modelin başarıları %95.52 olmuştur.

True Class	Antraknoz	147		7	2	94.2%	5.8%		
	Herikihastalik	4	109	3	9	87.2%	12.8%		
	Saglikli	1	4	548	2	98.7%	1.3%		
	VitaminEksikligi	7	5	3	198	93.0%	7.0%		
		92.5%	92.4%	97.7%	93.8%	7.5%	7.6%	2.3%	6.2%
		Antraknoz	Herikihastalik	Saglikli	VitaminEksikligi	Predicted Class			

Şekil 5.3. AlexNet'e ait 100 epoch ve SDGM algoritması için karışıklık matrisi

GoogleNet en iyi başarıyı 100 epoch SDGM optimizasyon algoritmasında yakalamıştır. Şekil 5.4'de bu modele ait karışıklık matrisi gösterilmiştir. Bu modelin başarısı %97.14 olmuştur.

True Class	Antraknoz	147		7	2	94.2%	5.8%
	Herikihastalik		119	3	3	95.2%	4.8%
	Saglikli	1		549	5	98.9%	1.1%
	VitaminEksikligi	1	2	6	204	95.8%	4.2%

98.7%	98.3%	97.2%	95.3%
1.3%	1.7%	2.8%	4.7%

Antraknoz   Herikihastalik   Saglikli   VitaminEksikligi  
Predicted Class

Şekil 5.4. GoogleNet'e ait 100 epoch ve SDGM algoritması için karışıklık matrisi

SqueezeNet en iyi başarıyı 100 epoch Adam optimizasyon algoritmasında yakalamıştır. Şekil 5.5'de bu modele ait karışıklık matrisi gösterilmiştir. Bu modelin başarısı %96.57 olmuştur.

True Class	Antraknoz	147	3	3	3	94.2%	5.8%
	Herikihastalik	1	118	2	4	94.4%	5.6%
	Saglikli	8		544	3	98.0%	2.0%
	VitaminEksikligi	3	2	4	204	95.8%	4.2%
		92.5%	95.9%	98.4%	95.3%		
		7.5%	4.1%	1.6%	4.7%		
		Antraknoz	Herikihastalik	Saglikli	VitaminEksikligi	Predicted Class	

Şekil 5.5. SqueezeNet'e ait 100 epoch ve SDGM algoritması için karışıklık matrisi

Literatürde Faster R-CNN derin öğrenme modeli ile farklı alanlarda yapılan akademik çalışmalarda sınıflandırma başarı oranları ile bu tez çalışmasında geliştirilen Faster R-CNN modelin sınıflandırma başarı oranlarının karşılaştırılması Çizelge 5.7' de gösterilmiştir.

Çizelge 5.7 Literatürde Faster R-CNN modeli ile yapılmış sınıflandırma çalışmalarının karşılaştırması

Yazar & Yıl	Amaç	Yöntem	Başarı Oranı
(Cömert ve diğerleri, 2019)	Elmalarda çürük tespiti ve sınıflandırılması	Faster R-Cnn	84,95
(Altaş ve diğerleri, 2023)	Bazı bağ hastalıklarının tespiti ve sınıflandırılması	- Faster R-Cnn - SSD Multibox - Özgün Yeni Geliştirilen Model	92 92,21 96,95
(Ünsal ve Adem, 2023)	Diş röntgen görüntüleri üzerinden çürük seviyesinin sınıflandırılması	- Faster R-Cnn - YOLOv5	86,7 92,7
(Biçici, 2023)	Mammogram görüntülerindeki lezyonların tespiti ve sınıflandırılması	Faster R-Cnn ile birlikte kullanılan - InceptionV2 - Resnet101 - Resnet50	97,16 94,74 99,63

Çizelge 5.7. (devamı)

(Kıvrak ve Gürbüz, 2023)	Kabuklu fındık meyvesinde kusurlu meyvelerin tespiti ve sınıflandırılması	Faster R-Cnn	92
(Ghoury, 2019)	Üzüm ve üzüm yaprak hastalıklarının tespiti	-Faster R-Cnn InceptionV2 - SSD MobilenetV1	95,57 59,29
<b>Geliştirilen Yöntem</b>	<b>Ceviz yaprak hastalıkları ve mineral eksikliklerinin sınıflandırılması</b>	<b>Faster R-Cnn</b>	<b>98,28</b>

## 6. SONUÇ VE ÖNERİLER

Son yıllarda birçok sektörde olduğu gibi tarım alanında da çeşitli problemlerin çözümünde derin öğrenme yöntemleri sıklıkla kullanılmaya başlanmıştır. Literatürde, bitkilerdeki hastalıkların tespit ve sınıflandırılmasına yönelik pek çok bilimsel çalışma farklı derin öğrenme yöntemleri ile yapılmıştır.

Bu tez çalışmasında, ceviz yapraklarında kendini gösteren hastalık ve besleme bozukluklarından bazılarının farklı derin öğrenme modelleri ile tespit edilerek sınıflandırılması yapıldı. Çalışma kapsamında öncelikle yaprak görsellerinden veri seti oluşturuldu. Sağlıklı, antraknozlu, vitaminsiz ve her iki hastalığa sahip olmak üzere sınıflandırılan veri setindeki görüntülere çeşitli veri artırma teknikleri uygulanarak veri seti görüntü sayıları çoğaltıldı. Çalışmada geliştirilen Faster R-CNN modeli ile bilinen ön eğitilmiş ESA modellerinden AlexNet, GoogleNet ve SqueezeNet modellerinden her birinin Adam ve SGDM optimizasyon algoritmalarında farklı epoch değerlerindeki sınıflandırma başarıları ölçüldü. Geliştirilen Faster R-CNN derin öğrenme modeli ile %98.28, diğer ESA modellerinden GoogleNet, AlexNet ve SqueezeNet modellerinde sırasıyla %97.14, %95.52 ve %96.57 doğruluk (accuracy) oranları elde edildi. Elde edilen doğruluk değerlerine göre geliştirilen Faster R-CNN derin öğrenme modelinin bazı ceviz hastalıkları ile mineral yetersizliklerinin tespiti ve sınıflandırılmasında başarı ile kullanılabileceği düşünülmektedir.

Çalışmada kullanılan veri seti, farklı ceviz türlerindeki hastalık ya da mineral yetersizliklerinin tespitini de kapsayacak şekilde geliştirilerek daha kapsamlı bir model geliştirilebilir.

Hastalık tespiti ya da çeşitli mineral eksiklikleri günümüzde bir zirai uzman ya da laboratuvar şartlarında tespit edilmektedir. Bu durum hem maliyetli hem de zaman alıcıdır. Veri seti biraz daha artırılıp kendi içerisinde her bir minereal (bor, demir, magnezyum ve potasyum) eksikliğine göre tektar sınıflandırılarak doğrudan eksik olan mineralin tespit ve sınıflandırılması amacıyla çalışma yapılabilir.

## KAYNAKLAR

- Aksoy, B., Halis, H. D., ve Salman, O. K. M. (2020). Elma Bitkisindeki Hastalıkların Yapay Zekâ Yöntemleri ile Tespiti ve Yapay Zekâ Yöntemlerinin Performanslarının Karşılaştırılması. *International Journal of Engineering and Innovative Research*, 2(3), 194-210.
- Altaş, Z., Özgüven, M. M., ve Adem, K. (2023). Bazı Bağ Hastalıklarının Faster R-CNN Modeli ile Otomatik Tespit Edilmesi ve Sınıflandırılması. *Turkish Journal of Agriculture-Food Science and Technology*, 11(1), 97-103.
- Aslan, M. (2021). Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*(23), 540-546.
- Aslansoy, B. (2012). Sultandağı (Afyon) Yöresi Cevizlerinin (*Juglans regia* L.) Seleksiyon Yoluyla Islahı Üzerine Araştırmalar. *Yüksek Lisans, Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.
- Biçici, Y. (2023). *Derin öğrenme ile mammogram görüntülerindeki lezyonların tespiti ve sınıflandırılması* Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü].
- Bozcu, H. (2024). *Derin Öğrenme Tabanlı Kiraz Yapraklarında Hasar Tespiti* Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü].
- Bremer, H. (1954). Türkiye fitopatolojisi. Bahçe kültürleri hastalıkları.C.3. *İstiklal Matbaası Ankara*, 103.
- Budak, Y. (2010). Ceviz Yetiştiriciliği. *Samsun İl Tarım Müdürlüğü, Çiftçi Eğitimi ve Yayım Şubesi Yayını*.
- İnternet: *Cevizde Besin Elementi Eksiklikleri*. (2016). <https://ceviztarlam.wordpress.com/2016/04/24/cevizde-besin-elementi-eksiklikleri/>
- Cömert, O., Hekim, M., ve Adem, K. (2019). Faster R-CNN kullanarak elmalarda çürük tespiti. *International Journal of Engineering Research and Development*, 11(1), 335-341.
- Çetiner, H., ve Çetiner, İ. (2022). Konvolüsyonel sinir ağı tabanlı derin öğrenme modeli ile narenciye hastalıklarının sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(1), 352-368.
- Dobrescu, A., Giuffrida, M. V., and Tsaftaris, S. A. (2020). Doing more with less: a multitask deep learning approach in plant phenotyping. *Frontiers in plant science*, 11, 477019.
- Doğan, F., ve Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.

- Du, Y., Shen, W., Liu, B., Lu, W., and Gong, H. (2021). Dual Batch Size Training: An efficient MGD adaptive batch size method. 2021 IEEE 33rd International Conference on Tools with Artificial Intelligence (ICTAI),
- Ecemiş, İ. N. (2022). Domates yapraklarında hastalık tespiti için önerilen hafif evrişimli sinir ağı ile önceden eğitilmiş ağların performans karşılaştırması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(2), 693-706.
- Eken, C., ve Demirci, E. (1998). Erzurum ilinde meyve ağaçlarında görülen fungal etmenler. *Doğu Anadolu Tarım Kongresi*, 106-112.
- Faster, R. (2015). Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 9199(10.5555), 2969239-2969250.
- Ghoury, S. (2019). Konvolüsyonel sinir ağlarını kullanarak üzüm ve üzüm yapraklarının hastalıklarının tespit edilmesi.
- Girshick, R., Donahue, J., Darrell, T., and Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.
- Gökalp, Ö. M. (2022). Makine öğrenmesi. *Gazi Üniversitesi, Gazi BilişimEnstitüsü, Adli Bilişim Bölümü*.
- Gökçe, A. Y., Turak, S., Albayrak, S., ve Akbaş, H. R. (2011). Doğu Anadolu Bölgesinde meyve ağaçlarında sorun olan fungal etmenlerin tespiti. *Bitki Koruma Bülteni*, 51(1), 33-44.
- Göksu, M., Sünnetci, K. M., ve Alkan, A. (2021). Derin öğrenme ağları kullanılarak mısır yapraklarında hastalık tespiti. *Computer Science(Special)*, 208-216.
- Gülmez, B. (2023). Parçacık sürü optimizasyonu destekli derin öğrenme ile gül yaprağı hastalık tespiti.
- İnternet: Gürbüz, F. B. (2020). *Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)*. Retrieved 11.05.2024 from <https://medium.com/@batincangurbuz/konvol%C3%BCsyonel-sinir-a%C4%9Flar%C4%B1-evri%C5%9Fimli-sinir-a%C4%9Flar%C4%B1-olarak-da-bililir-convolutional-neural-4ecd2c5ad842>
- Han, X., Zhang, Z., Ding, N., Gu, Y., Liu, X., Huo, Y., Qiu, J., Yao, Y., Zhang, A., and Zhang, L. (2021). Pre-trained models: Past, present and future. *AI Open*, 2, 225-250.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.

- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- İnik, Ö., ve Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Karadeniz, A. T. (2023). *Yaprak Görüntülerini Kullanarak Derin Öğrenme İle Ceviz Türlerinin Belirlenmesi*
- İnternet: Kaya, F. *GoogleNet Architecture*. [https://www.researchgate.net/figure/GoogleNet-Architecture-23-27\\_fig4\\_351975181](https://www.researchgate.net/figure/GoogleNet-Architecture-23-27_fig4_351975181)
- Kayaalp, K., ve Altınalan, A. (2023). Ceviz sürgün görüntüleri kullanılarak ceviz çeşitlerinin sınıflandırılması. *Uluborlu Mesleki Bilimler Dergisi*, 6(2), 42-52.
- Kıvrak, O., ve Gürbüz, M. Z. (2023). Kabuklu Fındık Meyvesinde Derin Öğrenme Tabanlı Kusurlu Meyvelerin Tespiti. *Akademik Ziraat Dergisi*, 12(Özel Sayı), 271-276.
- Krizhevsky, A., Sutskever, I., and Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. Vol 25.; 2012. [http://books.nips.cc/papers/files/nips25/NIPS2012\\_534\\_1097-1105](http://books.nips.cc/papers/files/nips25/NIPS2012_534_1097-1105).
- Kuş, Z. (2019). *Mikrokanonikal optimizasyon algoritması ile konvolüsyonel sinir ağlarında hiper parametrelerin optimize edilmesi* Fatih Sultan Mehmet Vakıf Üniversitesi, Lisansüstü Eğitim Enstitüsü].
- Nair, V., and Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. Proceedings of the 27th international conference on machine learning (ICML-10),
- Öztürk, K., ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- İnternet: PseudoLab. (2020). *Nesne Algılamaya Giriş*. <https://pseudo-lab.github.io/Tutorial-Book-en/chapters/en/object-detection/Ch1-Object-Detection.html>
- İnternet: Simsek, H. K. (2018). *Sınıflandırma Modellerinde Başarı Kriterleri*. <https://medium.com/data-science-tr/s%C4%B1n%C4%B1fland%C4%B1rma-modellerinde-ba%C5%9Far%C4%B1-kriterleri-2d86488799c6>
- Tezcan, H. (2005). Bazı önemli ceviz hastalıkları ve bunlara karşı bir entegre mücadele (ıpm) yaklaşımı. *Bahçe*, 34(1), 187-192.
- Uysal, N. (2020). *Zeytin yaprağındaki hastalıkların derin öğrenme teknikleri kullanılarak sınıflandırılması* Lisansüstü Eğitim Enstitüsü].
- Ünsal, Ü., ve Adem, K. (2023). Dış görüntüleri üzerinde görüntü işleme ve derin öğrenme yöntemleri kullanılarak çürük seviyesinin sınıflandırılması. *Uluslararası Sivas Bilim ve Teknoloji Üniversitesi Dergisi*, 2(2), 30-53.

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.

İnternet: Yıldırım, N. (2013). *Cevizde Besin Yetersizliği*. <https://ceviz.info/tag/ceviz-besin-yetersizligi/>

Zeki, C., ve Özdem, A. (2013). Ceviz bahçelerinde Elma içkurdu [(*Cydia pomonella* L.)(Lep.: Tortricidae)]'nın mücadelesinde tahmin ve uyarı sisteminin oluşturulmasına yönelik çalışmalar. *Bitki Koruma Bülteni*, 53(3), 127-140.



## ÖZGEÇMİŞ

**Adı-Soyadı** : Kadir AYGÜN

<b>Eğitim Derecesi</b>	<b>Okul/Program</b>	<b>Mezuniyet Yılı</b>
Lisans	Fırat Üniversitesi - Bilgisayar Öğretmenliği	2001
Lisans	Gazi Osman Paşa Üniversitesi - Bilgisayar Mühendisliği	2021
Yüksek Lisans (Tezsiz)	Amasya Üniversitesi - Teknoloji ve Inovasyon Yönetimi	2021

**Yabancı Dil** : İngilizce

**İş Deneyimi/Yıl** : **Çalıştığı Yer**  
2001 - İlduş Hatun Mesleki ve Teknik Anadolu Lisesi

### **Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)**

Kadir Aygün, Y. Ü. (2022, 6-8.5.2022). Classification and comparison of rice types with inceptionv3 and inceptionresnetv2 deep learning models. Istanbul International Moder Scientific Research Congress–III,