



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

**FINDIK MEYVE ÇEŞİTLERİNİN DERİN ÖĞRENME METODU
KULLANILARAK SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

SELÇUK HARMANCI

ŞUBAT

**FINDIK MEYVE ÇEŞİTLERİNİN DERİN ÖĞRENME METODU
KULLANILARAK SINIFLANDIRILMASI**

Selçuk HARMANCI

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

Danışman

Dr. Ör. Üyesi Yavuz ÜNAL

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ŞUBAT 2025

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Selçuk HARMANCI tarafından hazırlanan “Fındık Meyve Çeşitlerinin Derin Öğrenme Metodu Kullanılarak 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

Başkan: Dr. Öğr. Üyesi İnayet Hakkı ÇİZMECİ

Bilgisayar Yazılımı Anabilim Dalı, Afyon Kocatepe Üniversitesi

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

Üye: Dr. Öğr. Üyesi Çetin Cem BÜKÜCÜ

Teknoloji ve İnovasyon Yönetimi Anabilim Dalı, Amasya Üniversitesi

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

Tez Savunma Tarihi: 06/02/2025

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)

Selçuk HARMANCI

(Tarih)

FINDIK MEYVE ÇEŞİTLERİNİN DERİN ÖĞRENME METODU KULLANILARAK SINIFLANDIRILMASI

(Yüksek Lisans Tezi)

Selçuk HARMANCI

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Şubat 2025

ÖZET

Fındık, *Corylaceae* (gürgengiller) familyasına ait bir kabuklu yemiş türü olup, dünya genelinde özellikle Türkiye'de yoğun olarak yetiştirilmektedir. Türkiye, Karadeniz Bölgesi'nde yer alan illeriyle, fındık üretiminde önde gelen bir merkez konumundadır ve dünya çapında önemli bir ihracatçı rolü üstlenmektedir. Fındık, protein, yağ, lif, vitamin ve mineral yönünden zengin bir besin kaynağı olup, geniş bir kullanım yelpazesine sahiptir. Bu çalışmada, Türkiye'de yaygın olarak yetiştirilen fındık türlerinden sekiz tanesi ön eğitilmiş ağlar kullanılarak sınıflandırması amaçlanmaktadır. Çalışma kapsamında bilgisayarlı görü sistemi aracılığıyla fındık çeşitlerinin görüntüleri elde edilmiştir. Oluşturduğumuz veri setinde 150 palaz, 320 dağ, 380 Foşa, 230 tombul, 380 hanımeli, 320 çakıldak, 420 kara fındık, 390 sivri, toplam 2590 adet görüntü bulunmaktadır. Bu görüntüler ön eğitilmiş (pre-trained) modeller, DenseNet121, Inception v3, NasNet, EfficeNet, AlexNet ve Xception ile fındık görüntüleri sınıflandırılmıştır. Veri kümesi %80 eğitim ve %20 test olmak üzere bölümlere ayrılmıştır. Yapılan sınıflandırmalar sonucunda; sırasıyla %95,17, %93,44, %80,07, %81,17, %79,73 ve %83,20 sınıflandırma başarıları elde edilmiştir. En yüksek sınıflandırma başarıları DenseNet121 modeli ile elde edilmiştir. Çeşitli karışıklık matrisleri ve performans ölçümleri modellerin performanslarını daha detaylı analiz etmek için kullanılmıştır. İkinci aşamada veri artırımı teknikleri kullanılarak görüntüler çoğaltılmış ve yeniden sınıflandırma işlemine tabi tutulmuştur. Çoğaltılmış verilere uygulanan ön eğitilmiş (pre-trained) modeller sırasıyla şunlardır; Densenet121, AlexNet, NasNet, Xception, Inception V3, VGG16, EfficeNet ve VGG-19. Bu derin öğrenme metodları eğitim başarı oranları sırasıyla şunlardır; %97,5, %91,16, %81,61, %82,77, %95,45, %92,95, %78,66, %82,95. Veri artırma işleminin sonucunda bazı modellerde sınıflandırma başarıları artmış bazılarında artmamıştır. Elde edilen sonuçlar tezin ilgili bölümünde detaylı olarak verilmiştir.

Sayfa Adedi : 133

Anahtar Kelimeler : Fındık Çeşitleri, Eğitilmiş Ağlar, Derin Öğrenme, Görüntü İşleme

Danışman : Dr. Öğr. Üyesi Yavuz ÜNAL

CLASSIFICATION OF HAZELNUT FRUIT VARIETIES USING DEEP LEARNING METHOD

(M. Sc. Thesis)

Selçuk HARMANCI

AMASYA UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

February 2025

ABSTRACT

Hazelnut is a type of nut that belongs to the Corylaceae family and is grown intensively worldwide, especially in Turkey. Turkey, with its provinces located in the Black Sea Region, is a leading center in hazelnut production and plays a significant export role worldwide. The examination of acres of hazelnut gardens by experts requires long periods of time and leads to high costs. In this study, it is aimed to classify eight of the hazelnut species commonly grown in Turkey using pre-trained networks. Within the scope of the study, images of hazelnut varieties were obtained through a computer vision system. The dataset we created includes 150 palaz, 320 mountain, 380 Foşa, 230 tombul, 380 honeysuckle, 320 çakdak, 420 black hazelnut, 390 spike, a total of 2590 images. These images were classified as hazelnut images with pre-trained models, DenseNet121, Inception v3, NasNet, EfficeNet, AlexNet and Xception. The dataset was divided into 80% training and 20% test sections. As a result of the classifications; 95,17%, 93,44%, 80,07%, 81,17%, 79,73% and 83.20% classification success was obtained, respectively. The highest classification success was obtained with the DenseNet121 model. Various confusion matrices and performance measurements were used to analyze the performances of the models in more detail. In the second stage, the images were multiplied using data augmentation techniques and subjected to re-classification. Pre-trained models applied to replicated data are; Densenet121, AlexNet, NasNet, Xception, Inception V3, VGG16, EfficeNet and VGG-19, respectively. The training success rates of these deep learning methods are; 97,5%, 91,16%, 81,61%, 82,77%, 95,45%, 92,95%, 78,66%, 82,95%. As a result of the data augmentation process, the classification success increased in some models and did not increase in others. The results obtained are given in detail in the relevant section of the thesis.

Number of pages : 133

Keywords : Hazelnut Varieties, Pre-trained Networks, Deep Learning, Image Processing

Supervisor : Asst. Prof. Dr. Yavuz ÜNAL

ÖNSÖZ ve TEŞEKKÜR

Bu çalışmanın yürütülmesi sırasında desteğini esirgemeyen ve tecrübelerinden faydalandığım Dr. Öğr. Üyesi Yavuz ÜNAL'a, çalışma sırasında her daim yanımda olan ve motivasyon desteği veren Uzman Öğretmen Barış ATEŞ'e, çalışmam sırasında bana gösterdiği sabır ve anlayıştan ötürü eşim Raziye hanıma, bana sürekli destek verdikleri için oğullarım Kağan ve Çağan'a, çalışmam sırasında zaman ve mekan konusunda bana sürekli destek olan Başöğretmen Gürsel ÇAYLAK'a ve çalışmam sırasında desteklerini esirgemeyen herkese teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
ÖNSÖZ ve TEŞEKKÜR	vi
ÇİZELGELER DİZİNİ	x
ŞEKİLLER DİZİNİ	xii
RESİMLER DİZİNİ	xvi
SİMGELER VE KISALTMALAR DİZİNİ	xvii
1.GİRİŞ.....	1
1.1 Kültür Fındığının Tarihi ve Yetiştirilme Bölgeleri	1
1.2 Fındık Üretimi ve Küresel Durumu	2
1.2 Fındık Bitkisinin Özellikleri	2
1.3.1 Fındığın iklimsel özellikleri ve yetiştirme alanları	2
1.3.2 Fındık bitkisinin biyolojik özellikleri ve yetiştirme süreci.....	4
1.3.3 Yaprak yapısı.....	5
1.3.4 Zuruf yapısı.....	5
1.4 Çalışmada Kullanılan Fındık Çeşitleri.....	8
1.4.1 Hanımeli fındığı.....	8
1.4.2 Çakıldak fındık	9
1.4.3 Foşa fındığı (devediş).....	9
1.4.5 Kara fındık.....	10
1.4.6 Palaz fındık	10
1.4.7 Sivri fındık.....	11

1.4.8 Tombul findık.....	11
1.4.9 Dağ findığı.....	12
2. LİTERATÜR İNCELEMESİ.....	13
3.MATERYAL ve METOD.....	20
3.1 Veri Seti	20
3.2 Görüntü Elde Edilmesi.....	22
3.3 Görüntülerin Ön İşlemden Geçirilmesi.....	22
3.3.1 Veri artırımı	23
3.3.2 Yaygın veri artırma teknikleri şunları içerir	24
3.4 Önerilen Model	26
3.5 Yapay Sinir Ağları (YSA)	28
3.6 Derin Öğrenme.....	34
3.7 Transfer Öğrenme	38
3.8 DenseNet121 Modeli	42
3.9 Inception V3 Modeli	45
3.10 Xception Modeli	48
3.11 VGG Modeli	50
3.12 EfficienNet Modeli	52
3.13 NasNet Modeli	53
3.14 AlexNet Modeli	54
4. PERFORMANS DEĞERLENDİRMESİ	56
4.1 Hesaplama Formülleri.....	56
5.DENEYSEL SONUÇLAR.....	59
5.1 DenseNet121 Modeli	60
5.2 Inception V3 Modeli	63

5.3 Xception Modeli	66
5.4 EfficientNet Modeli	69
5.5 NasNet Modeli	72
5.6 AlexNet Modeli	75
5.7 VGG16 Modeli	78
5.8 VGG19 Modeli	81
5.9 Veri Artırma işlemi yapılmış veri seti	84
5.9.1 DenseNet121 Artırılmış Veri Seti Modeli.....	100
5.9.2 AlexNet Artırılmış Veri Seti Modeli	103
5.9.3 NasNet Artırılmış Veri Seti Modeli.....	106
5.9.4 Xception.....	109
5.9.5 InceptionV3 Artırılmış Veri Seti Modeli.....	112
5.9.6 EfficientNet Artırılmış Veri Seti Modeli.....	115
5.9.7 VGG16 Artırılmış Veri Seti Modeli	118
5.9.8 VGG19 Artırılmış Veri Seti Modeli	121
6. SONUÇLAR VE ÖNERİLER	125
KAYNAKLAR	127
ÖZGEÇMİŞ	133

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 2.1 Bu alanda yapıla çalışmalar.....	15
Çizelge 3.1 Artırma teknikleri	26
Çizelge 3.2 Artırma öncesi ve sonrası görüntü sayıları.....	27
Çizelge 5.1 Orjinal veri setinin sınıflandırılması ile elde edilen başarı değerleri.	60
Çizelge 5.2 DenseNet121 doğrulama sonuçları.....	61
Çizelge 5.3 Inception V3 doğrulama sonuçları.....	67
Çizelge 5.4 Xception doğrulama sonuçları.....	71
Çizelge 5.5 EfficientNet doğrulama sonuçları.....	75
Çizelge 5.6 NasNet doğrulama sonuçları.....	79
Çizelge 5.7 AlexNet doğrulama sonuçları.....	83
Çizelge 5.8 VGG 16 doğrulama sonuçları.....	87
Çizelge 5.9 VGG 19 doğrulama sonuçları.....	91
Çizelge 5.10 Artırılmış sınıflandırmada elde edilen başarı sayıları.	93
Çizelge 5.11 Veri artırma işlemi yapılmış veri seti doğrulama sonuçları.....	96
Çizelge 5.12 Veri artırma işlemi yapılmış veri seti doğrulama sonuçları.....	100
Çizelge 5.13 Veri Artırma işlemi yapılmış veri seti doğrulama sonuçları.....	104
Çizelge 5.14 Veri Artırma işlemi yapılmış veri seti doğrulama sonuçları.....	108
Çizelge 5.15 Veri Artırma işlemi yapılmış veri seti doğrulama sonuçları.....	112
Çizelge 5.16 Veri Artırma işlemi yapılmış veri seti doğrulama sonuçları.....	116
Çizelge 5.17 Veri Artırma işlemi yapılmış veri seti doğrulama sonuçları.....	120

Çizelge 5.18 Veri Artırma işlemi yapılmış veri seti doğrulama sonuçları.....	124
--	-----



ŞEKİLLER DİZİNİ

Şekiller	Sayfa
Şekil 1.1 Hanımeli fındığı (Url-6).....	8
Şekil 1.2: Çakıldak fındık (Url-7).....	9
Şekil 1.3 Foşa fındık (Url-8).	9
Şekil 1.4 Kara fındık (Url-9).....	10
Şekil 1.5 Palaz fındık (Url-9).....	11
Şekil 1.6 Sivri fındık (Url-10)	11
Şekil 1.7 Tombul Fındık (Url-9)	12
Şekil 1.8 Dağ fındığı (Url-9)	12
Şekil 3.1 Kullanılan fındık türleri ve sayıları.....	21
Şekil 3.2 Çalışmada kullanılan Fındık Türleri.....	22
Şekil 3.3 Veri aktarımında kullanılan düzenek.....	23
Şekil 3.4 Veri artırma (Url-11).....	24
Şekil 3.6 Kullanılan yapıya ait şema.....	28
Şekil 3.7 Veri Hazırlama Şeması.....	29
Şekil 3.8 Yapay Sinir Ağı (Url-13).	30
Şekil 3.9 İnsan Beyni Nöron Yapısı ve Yapay Zeka Nöron Yapısı Karşılaştırması.....	31
Şekil 3.10 Yapay Sinir Ağları (YSA) (Xiong et al., 2021).....	33
Şekil 3.5 Network Sinir Ağları Örnekleri (Url-12).....	34
Şekil 3.11 Derin Öğrenme Şeması (Url-15).....	35
Şekil 3.12 Yapay Sinir Ağı Örneği (Url-16).....	36
Şekil 3.13 Uçtan Uca Öğrenme (Url-17).....	37
Şekil 3.14 Derin öğrenme, makine öğrenmesi ve yapay zeka ilişkisi.....	38
Şekil 3.15 Aktarılan bilginin biçimine göre öğrenme yaklaşımları.....	39

Şekil 3.16 Örnek Transfer Öğrenme Şeması (Url-18).....	40
Şekil 3.17 Transfer Öğrenme.....	43
Şekil 3.18 DenseBlock, convblock ve geçiş katmanı.....	44
Şekil 3.19 İnception v3 modelinin yapı şeması.....	48
Şekil 3.20 İnception v3 modelinin veri işleme şeması.....	49
Şekil 5.1 50 Dönem DenseNet 121 doğrulama eğrileri grafiği.....	62
Şekil 5.2 50 Dönem DenseNet 121 doğrulama kaybı eğrileri.....	63
Şekil 5.3 Confusion matrix kullanımı DenseNet121.....	64
Şekil 5.4 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında İnception v3 modelinin eğitim ve doğrulama grafiği.	65
Şekil 5.5 Fındık çeşidi sınıflandırması için İnception v3 modelinin eğitim ve doğrulama kaybı.....	66
Şekil 5.6 Confusion matrix kullanımı İnception v3.....	67
Şekil 5.7 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Xception modelinin eğitim ve doğrulama grafiği.	69
Şekil 5.8 Fındık çeşidi sınıflandırması için model eğitimi sırasında Xception modelinin eğitim ve doğrulama kaybı görülmektedir.....	70
Şekil 5.9 Confusion matrix kullanımı Xception.....	71
Şekil 5.10 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında EfficientNet modelinin eğitim ve doğrulama grafiği.....	73
Şekil 5.11 Fındık çeşidi sınıflandırması için model eğitimi sırasında EfficientNet modelinin eğitim ve doğrulama kaybı görülmektedir.....	74
Şekil 5.12 Confusion matrix kullanımı EfficientNet.....	74
Şekil 5.14 Fındık çeşidi sınıflandırması için model eğitimi sırasında NasNet modelinin eğitim ve doğrulama kaybı görülmektedir.	78
Şekil 5.16 Confusion matrix kullanımı NasNet.....	79
Şekil 5.17 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında AlexNet modelinin eğitim ve doğrulama grafiği.	81

Şekil 5.18 Fındık çeşidi sınıflandırması için model eğitimi sırasında AlexNet modelinin eğitim ve doğrulama kaybı görülmektedir.	82
Şekil 5.19 Confusion matrix kullanımı NasNet.....	83
Şekil 5.20 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında VGG 16 modelinin eğitim ve doğrulama grafiği.	85
Şekil 5.21 Fındık çeşidi sınıflandırması için model eğitimi sırasında VGG 16 modelinin eğitim ve doğrulama kaybı görülmektedir.	86
Şekil 5.22 Confusion matrix kullanımı VGG 16.....	87
Şekil 5.23 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında VGG 19 modelinin eğitim ve doğrulama grafiği.	89
Şekil 5.24 Fındık çeşidi sınıflandırması için model eğitimi sırasında VGG 19 modelinin eğitim ve doğrulama kaybı görülmektedir.	90
Şekil 5.25 Confusion matrix kullanımı VGG 19.....	91
Şekil 5.26 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.....	94
Şekil 5.27 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	95
Şekil 5.28 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.	96
Şekil 5.29 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.	98
Şekil 5.30 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	99
Şekil 5.31 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.....	100
Şekil 5.32 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.	102
Şekil 5.33 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	103
Şekil 5.34 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.....	104
Şekil 5.35 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.	106
Şekil 5.36 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	107

Şekil 5.37 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.	108
Şekil 5.38 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.....	110
Şekil 5.39 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	111
Şekil 5.40 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.....	112
Şekil 5.41 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.....	114
Şekil 5.42 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	115
Şekil 5.43 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.	116
Şekil 5.44 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.....	118
Şekil 5.45 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.....	119
Şekil 5.46 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.....	120
Şekil 5.47 Fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.....	122
Şekil 5.48 Fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.	123
Şekil 5.49 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.....	124

RESİMLER DİZİNİ

Resim	Sayfa
Resim 1.1 Fındık bitkisi ve meyvesi	3
Resim 1.2 Fındık bitkisinin dalları ve gövdesi	4
Resim 1.3 Fındık Yaprak Yapısı	5
Resim 1.4 Zuruf (Kabuk Dış Zarı)	6
Resim 1.5 Fındık İç Yapısı.....	7
Resim 3.21 Xception modeli	50
Resim 3.22 VGG-16 modeli	51
Resim 3.23 EfficientNet modeli	52
Resim 3.24 NasNet modeli	55
Resim 3.25 AlexNet modeli	56

SİMGELER VE KISALTMALAR DİZİNİ

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

Kısaltmalar	Açıklama
ACC :	Accuracy (doğruluk)
ASPP : Piramit Havuzu)	Atrous Spatial Pyramid Pooling (Aşırı Uzaysal
CNN :	Convolutional Neural Network
CPU :	Central Processing Unit (Merkezi İşlem Birimi)
ESA :	Evrişimli Sinir Ağı
GPU :	Graphical Processing Unit (Grafik İşlem Birimi)
HU :	Hounsfield Unit
RAM : Belleği)	Random Access Memory (Rastgele Erişim
YSA :	Yapay Sinir Ağı
NLST :	National Lung Screening Trial

1.GİRİŞ

Fındık, Fagales takımından olan ve özellikle Betulaceae (Huşgiller) ailesine ait *Corylus* cinsinde yer alan bir bitki türüdür. Fındık bitkisi, genellikle küçük bir ağaç veya çalı formunda yetişir ve meyvesi, sert kabuklu ve besleyici özellikleriyle tanınır.

Fındık ürünü yoğunlukla dünyamızın kuzey yarım küresinde 42-45 enlem derecelerinde yer alan ılıman iklim kuşağında geniş bir alanda bulunmaktadır. Genellikle sahil bölgelerde ve ılıman iklimde daha iyi ürün verir. Bu duruma en iyi örnek Türkiye'nin Karadeniz bölgesi kıyı şeridi verilebilir (Islam, 2018).

1.1 Kültür Fındığının Tarihi ve Yetiştirilme Bölgeleri

Kültür fındığı olarak bilinen tür, özel iklim koşulları gerektirdiği için genellikle deniz kenarındaki yerleşim yerlerine yakın, sınırlı alanlarda yetiştirilmektedir. Bu türün temel yetiştirilme bölgesi, Türkiye'nin Karadeniz kıyılarıdır. Tarihsel kaynaklara göre, Anadolu'da fındık üretimi M.Ö. 3. ve 4. yüzyıllara kadar uzanmaktadır (Balık, 2021).

Türkiye'de yetiştirilen fındık türleri, tarihsel süreçte Avrupa'ya, özellikle Yunanistan ve İtalya'ya taşınmış ve İtalya'nın Avellino bölgesinde üretimi yaygınlaşmıştır. Bu nedenle, söz konusu fındık türü, Avellino şehrine atfen *Corylus avellana* olarak adlandırılmıştır (Botta et al., 2019). Temel kökeni Anadolu'ya dayanan bu fındık türü, literatürde Avrupa fındığı olarak yerini almıştır. Yine İspanya ve İtalya'da kıyı bölgelerde fındık ürünü üretimi yaygın olarak yapılır (Islam, 2003).

ABD de ise fındık üretimi Pasifikten etkilenen Williamette bölgesinde yapılmaktadır. Kafkaslar ve Balkanlar da önemli üretim alanı olmaktadır. Çin ve Hindistan gibi farklı ekolojilerde de fındık çeşitleri yetiştirilmektedir. Diğer yandan son 20 yılda Şili gibi güney yarımkürede de yetiştiricilik artmaktadır (Islam ve Özgüven, 2001).

Ağaç formunda yetişen, özellikle ülkemizin Batı Karadeniz bölgesinde yoğunlukla bulunan ve Bolu Fındığı olarak da bilinen Türk Fındığı türü (*Corylus colurna* L.) de ülkemizde doğal olarak yetişmektedir. (Balık, 2021).

1.2 Fındık Üretimi ve Küresel Durumu

Fındık, badem ve ceviz gibi kabuklu yemişlerle birlikte dünya genelinde en fazla üretimi ve tüketimi yapılan kabuklu yemiş türlerinden biridir. Dünya genelinde fındık üretimi yapılan toplam alan 903.864 hektar olup, bu alan sert kabuklu meyvelerin toplam üretim alanının %20'sini oluşturmaktadır.

Küresel fındık üretiminde en büyük aktör Türkiye'dir. Ülkemiz, yaklaşık 703.000 hektarlık bir alanda üretim gerçekleştirmekte olup, bu miktar dünya genelindeki toplam üretim alanının %78'ine denk gelmektedir. Türkiye, yıllık ortalama 581.000 ton üretim ile dünya fındık üretiminin %70'ini karşılamaktadır (Balık, 2021).

Bu bilgiler, fındığın hem Türkiye'nin tarım sektöründeki stratejik önemini hem de dünya pazarındaki belirleyici rolünü ortaya koymaktadır.

Dünya genelinde diğer önemli üretici ülkeler ise İtalya, ABD, Gürcistan, Azerbaycan, Çin, İran ve İspanya'dır. Ülkemizde, fındık üretimi üretim miktarı açısından iki bölgeye ayrılabilir. Birinci bölge Samsun'dan Gürcistan sınırına kadar olan ve daha çok üretimin yapıldığı doğu Karadeniz bölgesi ve ikinci bölge ise Samsun'dan İstanbul'a kadar olan ve nispeten daha az üretimin yapıldığı batı Karadeniz bölgesidir.

Gıda tarım ve hayvancılık bakanlığı Çiftçi Kayıt Sistemine (ÇKS) verilerine göre ülkemizde 38 il genelinde fındık üretimi yapıldığı tespit edilmiştir (Gıda Tarım ve Hayvancılık Bakanlığı, 2024). Ancak, 01.01.2015 tarihinden itibaren geçerli olan karar ile 'Fındık Alanlarının Tespitine Dair Kararda Değişiklik Yapılmasına Dair Bakanlar Kurulu Kararı'na temel alınarak 16 ilimizde (Artvin, Bartın, Düzce, Giresun, Gümüşhane, Kastamonu, Kocaeli, Ordu, Rize, Sakarya, Samsun, Sinop, Trabzon, Zonguldak, Bolu, Tokat) ve bunlara bağlı 132 ilçe yasal fındık alanı olarak belirlenmiştir.

1.2 Fındık Bitkisinin Özellikleri

1.3.1 Fındığın iklimsel özellikleri ve yetiştirme alanları

Fındık bitkisi, nemli ve denize kıyısı bulunan bölgelerde yetiştirilen bir ürün olup, yetiştirilmesi sırasında yüksek sıcaklık ve don olaylarından önemli ölçüde etkilenmektedir. Bu nedenle,

ılıman iklime sahip, bol yağış alan bölgeler fındık tarımı için en uygun alanlardır. İlkbahar aylarında meydana gelen don olayları, fındık çiçeklerinin zarar görmesine ve soğuktan yanmalarına neden olabilmektedir.

Fındık bitkisinin yetiştirilmesi için uygun iklim koşulları şunlardır: yıllık ortalama sıcaklığın 12-17 °C arasında olması, kış aylarında sıcaklıkların -8 ila -11 °C'nin altına düşmemesi, yaz sıcaklıklarının ise 35-37 °C'yi aşmaması gerekmektedir. Ayrıca, yıllık yağış miktarının 700 mm nin üzerinde olması ve haziran-temmuz aylarında yağış alan bölgelerde yetiştirilmesi önemlidir (Balık et al., 2015).

Bu iklimsel koşullar göz önünde bulundurulduğunda, fındık tarımı için en uygun alanlar Türkiye'nin Karadeniz kıyılarıdır. Fındık, dağlık ve kayalık alanlarda yetiştirilebileceği gibi, Karadeniz Bölgesi'nde yer alan Çarşamba ve Bafra ovalarında da yoğun şekilde üretilmektedir (Balık et al., 2015).



Resim 1.1 Fındık bitkisi ve meyvesi (Aydın et al.,2024).

1.3.2 Fındık bitkisinin biyolojik özellikleri ve yetiştirme süreci

Fındık, ılıman iklim koşullarında yetişen bir bitki türüdür. Kış mevsiminde yapraklarını dökerek yalın bir ağaç görünümüne bürünür; yaz aylarında ise yapraklarını yeniden yeşerterek aktif büyüme dönemine girer. Türkiye’de yetiştirilen fındık türlerinin büyük bir kısmı, topraktan uzanan dallar şeklinde büyümektedir. Ancak, bölgesel farklılıklar nedeniyle tek gövdeli ağaç formunda yetişen genotipler de bulunmaktadır (Erdoğan et al., 2005).

Fındık bitkisi, genellikle küçük dallar şeklinde dikilerek yetiştirilir. Bulunduğu bölgenin iklim koşulları ve sulama oranlarına bağlı olarak, fındık bitkisi 8 ila 10 yıl içerisinde meyve vermeye başlamaktadır. Sonbahar aylarında, kartlaşmış dallar kesilerek yeni dalların gelişimi için alan açılmakta ve bu süreç, fındık üretimi boyunca düzenli olarak devam etmektedir. Fındık dalları, uygun koşullarda 5 ila 8 metre yüksekliğe kadar büyüebilmektedir (Karadeniz et al., 2009).



Resim 1.2 Fındık bitkisinin dalları ve gövdesi (Aydın et al.,2024).

Bu özellikleriyle fındık hem biyolojik hem de tarımsal açıdan belirgin bir üretim döngüsüne sahiptir.

1.3.3 Yaprak yapısı

Fındık ürünü yaprakları genel olarak yuvarlak yapılı yaklaşık olarak 10-12 cm aralığındadır. Kenarları dişli bir yapıya sahiptir ve kısa bir sap ile fındık dalına bağlıdır. Sonbaharda yapraklar dökülür (Karadeniz et al., 2006).



Resim 1.3 Fındık Yaprak Yapısı (Aydın et al.,2024).


1.3.4 Zuruf yapısı

Fındıkkabuklu meyvesi olgunlaşma sürecinde yeşil renkli dış zar ile çevrilidir. İlkbahar aylarında olgunlaşan ve fındığın sert kabuğunu dışarıdan saran bu yeşil renkli zuruf temmuz aylarından başlayarak ekim ayına kadar olgunlaşır ve kahverengi hale gelerek kurur. Ardından kabuklu fındık meyvesi zurufun içinden dökülür (Karadeniz et al., 2006).



Resim 1.4 Zuruf (Kabuk Dış Zarı) (Aydın et al.,2024).

Fındık, özellikle protein, sağlıklı yağlar, lif ve vitamin ve mineral açısından zengin bir besin kaynağıdır. Ayrıca içerdiği antioksidanlar sayesinde sağlık için faydalı olabilir ve kalp sağlığını destekleyebilir. Ancak fındık, yüksek kalori ve yağ içeriği nedeniyle tüketirken porsiyon kontrolü yapmak önemlidir (Amaral et al., 2006).



Resim 1.5 Fındık İç Yapısı (Aydın et al.,2024).

Ayrıca fındikkabuğunun aktif karbon olarak kullanılması, son yıllarda giderek popüler hale gelen bir uygulamadır. Fındikkabuğu, yüksek oranda karbon içerdiği için aktif karbon üretiminde kullanılabilir. Fındık ürünü tarımsal değer olarak ülkemize önemli bir getiri kaynağı sağlamaktadır (Yalçın ve Arol, 1993).

Derin öğrenme, yapay zekâ ve makine öğrenmesinin bir alt dalıdır. Derin öğrenme, yapay sinir ağları kullanarak büyük ve karmaşık veri setlerini analiz edebilir ve daha iyi sonuçlar elde etmek için bu verilerden öğrenme süreci geçirebilir. Derin öğrenme, ses tanıma, görüntü işleme, doğal dil işleme, oyun ve robot kontrolü gibi birçok alanda başarıyla kullanılmaktadır. Özellikle büyük veri setleri üzerinde çalışırken ve insanların manuel olarak çıkarabileceğinden daha karmaşık özellikler keşfetmek gerektiğinde derin öğrenme yöntemleri önemli bir rol oynar (Köklü et al., 2022).

Bu çalışmamızda tarımsal önemi ve endüstriyel açıdan ülkemizde oldukça önemli olan fındık ürününün derin öğrenme modelleri ile sınıflandırılması amaçlanmıştır.

Fındık cinsinin pek çok çeşidi bulunmaktadır. Ülkemizde bulunan fındık çeşitlerinin genel olarak kabul edilmiş isim sınıflandırılması bulunmadığı için bu çalışmada kullanılan fındık çeşidi isimleri, türlerin halk arasında en çok kullanılan isimleridir (Zeynep ve Hakan, 2023).


1.4 Çalışmada Kullanılan Fındık Çeşitleri

Tez çalışmasında kullanılan fındık çeşitlerine aşağıda değinilmiştir.

1.4.1 Hanımeli fındığı

Hanımeli fındığı, yerel fındık çeşitlerinden biri olup bazı bölgelerde "hanımeli" adıyla da anılmaktadır. Türkiye'nin diğer bölgelerinde nadiren görülmekle birlikte, özellikle Karadeniz Bölgesi'nde bu türe rastlanmaktadır. Hanımeli fındığı, ince kabuk yapısına sahip olması nedeniyle kolay kırılabilir özellik taşımaktadır. Kabuk oranının düşük, iç oranının ise yüksek olması bu türün dikkat çeken özelliklerindendir.

Ancak, iç meyvesinin düşük kaliteye sahip olması ve verimliliğinin az olması nedeniyle, üreticiler tarafından öncelikli olarak tercih edilmemektedir. Buna rağmen, Hanımeli fındığı kendine özgü bir aromaya sahiptir ve çıplak gözle diğer fındık çeşitlerinden kolaylıkla ayırt edilebilir (Çetin et al., 2020). Şekil 1'de Hanımeli fındık çeşidine ait görsel yer almaktadır.



Şekil 1.1 Hanımeli Fındığı (Resarchgate portalı,2024).

1.4.2 akıldak fındık

Sivri yapıya sahip iki uçtan sivri bir görünüme sahip fındık türüdür. Üretim olarak dayanıklı ve verimli bir yapıya sahip olduğu için özellikle orta Karadeniz bölgesinde oldukça geniş bir ekim alanına sahiptir. Bu fındık türü don olayına da dayanıklı bir tür olduğu için fındık üreticileri tarafından tercih edilen bir türdür (Turan ve İslam, 2016). Şekil 3’ te akıldak fındığa ait örnek bir resim verilmiştir.



Şekil 1.2: akıldak fındık (Resarchgate portalı,2024).

1.4.3 Foşa fındığı (devedişi)

Genel olarak Karadeniz bölgesinin tamamında yetiştirilen bir fındık türüdür. Kabuk kalınlığı düşük ve içyapısı kaliteli bir fındık türüdür. Dayanıklılık olarak düşük bir fındık türüdür (Kurt ve Doğan, 2020).

Şekil 3’te foşa fındığına ait bir örnek verilmiştir.



Şekil 1.3 Foşa fındık (Resarchgate portalı,2024).

1.4.5 Kara fındık

Kara fındık, kalın kabuklu bir fındık türü olup, diğer türlere kıyasla daha koyu renkli ve düşük yağ içeriğine sahiptir. Bu fındık çeşidi genellikle Karadeniz Bölgesi'nin yüksek rakımlı kesimlerinde yetiştirilmektedir (Gülsoy et al., 2019). Şekil 3'te kara fındık fındığına ait bir örnek verilmiştir.



Şekil 1.4 Kara fındık (Resarchgate portalı,2024).

1.4.6 Palaz fındık


Orta büyüklükte ve kalın kabuğa sahip bir fındık türüdür. Genelde dayanıklı bir tür olduğu için fındık üreticileri tarafından tercih edilir. İç yağ oranı yüksek ve iç meyvesi kaliteli bir fındık türüdür (Şen, 2018). Şekil 3'te palaz fındığına ait bir örnek verilmiştir.



Şekil 1.5 Palaz findık (Resarchgate portalı,2024).

1.4.7 Sivri findık

Adını sivri yapısından alan findık türüdür. Verim olarak yüksek olmasına rağmen iç meyve büyüklüğü küçük ve yağ oranı düşüktür. İnce yapılı ve kolay kırılabilen bir yapıya sahiptir. Yüksek verim miktarı nedeniyle üreticiler tarafından tercih edilmesine neden olmaktadır (Şahin, 2019). Şekil 3'te sivri findığa ait bir örnek verilmiştir.



Şekil 1.6 Sivri findık (Resarchgate portalı,2024).

1.4.8 Tombul findık

Adını tombul yapısından alan findık türüdür. İç yağ oranı oldukça yüksek ve iç meyvesi büyük bir findık türüdür (%50-52). İnce kabuklu bir yapıya sahip ve özellikle findık aromalı ürünlerde oldukça tercih edilmektedir (İslam, 2019). Şekil 3'te tombul findığa ait bir örnek

verilmiştir.



Şekil 1.7 Tombul Fındık ((Resarchgate portalı,2024).

1.4.9 Dağ fındığı

İç yağ oranı oldukça yüksek olan ve fındık içi kullanılan tüm sektörlerde en çok kullanılan fındık türüdür. İç doluluk oranı oldukça yüksektir. Verim miktarı çakıldak ve sivri fındık kadar olmasa da yüksektir (Özdemir et al., 1998). Şekil 3’te dağ fındığına ait bir örnek verilmiştir.



Şekil 1.8 Dağ fındığı (Resarchgate portalı,2024).

2. LİTERATÜR İNCELEMESİ

Bu bölümde, fındık çeşitlerinin sınıflandırılmasına yönelik literatürde yer alan araştırmalar incelenmiştir. Öncelikle fındık çeşitliliği ve sınıflandırma yöntemleri üzerine yapılan yapay zekâ ve derin öğrenme tabanlı uygulamaların bu alana katkıları değerlendirilmiştir.

Ünal ve Aktaş yaptıkları çalışmada fındık meyvesinin kabuklarını kıran ve fındık içlerini görüntüleyen bir sistem geliştirmişlerdir. Bu görüntüler üzerinden fındık kırma makinasından çıkan ürünleri undersized, damages kernel, whole kernel ve shell olarak sınıflandırılmışlardır. Sınıflandırma aşamasında pre-trained transfer learning modellerden InceptionV3 ve EfficientNet kullanarak sırasıyla %97,85 ve %99,28 sınıflama doğruluğu elde etmişlerdir.

Koç ve arkadaşları (2020) yaptıkları çalışmada fındık meyvesini kabuklu halde fotoğraflar üzerinden sınıflandıran bir sistem geliştirmişlerdir. Tombul sivri ve kara fındık çeşitlerini makine öğrenmesi ve derin öğrenme yöntemleri kullanarak sınıflandırmışlardır. Yaptıkları çalışmada kabuk sıkıştırma mukavemeti göz önünde bulundurularak boosting yöntemi %72, Bagging yöntemi (Random forest) %83 ve DL4J (Derin öğrenme algoritması) %71 sınıflandırma doğruluğu elde etmişlerdir.

Giraud ve arkadaşları (2018) yaptıkları çalışmada 2000 adet yarım kesilmiş iç fındıktan oluşan numune seti kullanmışlardır. Dijital kamera yardımı ile sağlam ve kusurlu (çürümüş ya da haşereden etkilenmiş) fındık içlerini görüntülemişlerdir. Kırmızı-Yeşil-Mavi (RGB) görüntü analizi kullanarak RGB görüntülerinin çok değişkenli analizine dayalı kusurlu fındık tanelerini (PLS-DA) hem de PLS-DA aralığına (iPLS-DA) algoritmalarını kullanarak kusurlu sınıflandırma modeli, yaklaşık %97'sini doğru bir şekilde sınıflandırmışlardır. Çürümüş ve zararlılardan etkilenen, test seti örneklerinin %92'sinden fazlası doğru şekilde sınıflandırma doğruluğu elde etmişlerdir.

Bayrakdar ve arkadaşları (2015) yaptıkları çalışmada 3 farklı fındık türünü görüntüler üzerinden sınıflandırmışlardır. Tombul, sivri ve badem türü fındık çeşidi görüntülerinden çap, yarıçap, alan gibi şekil ve boyut özelliklerinden yararlanarak %84 doğruluk oranına ulaşmışlardır.

Solak S. ve Altunışık U. (2018) yaptıkları çalışmada 25 adet fındık ürünü görüntüsünü kullanarak bu fındıkları küçük, orta ve büyük olarak sınıflandırılmışlardır. Yapılan bu çalışmada 1.3 Megapiksel CMOS, 640 x 480 çözünürlük ile Logitech C110 USB kamera kullanılarak görüntüler elde edilmiştir. Söz konusu görüntüler, Ubuntu 12.04 işletim ile çalışan bir bilgisayar üzerinde işlenmektedir. Görüntülerin işlenmesi ve sınıflandırılması aşamalarında OpenCV Kütüphanesi ve Weka yazılımları kullanılmıştır. Ortalama tabanlı ve K-means kümeleme yöntemleri kullanılarak fındık meyvelerinin küçük, orta ve büyük olarak sınıflandırılması gerçekleştirilmektedir. Yapılan bu çalışmada, gerçekleşen iki algoritma ile sınıflandırmanın %90 ile %100 oranlarında benzerlik gösterdiği tespit edilmektedir.

Güvenç ve arkadaşları (2015) fındık iç görüntülerini zarlı, zarsız ve çürük olarak üç sınıfa ayırmışlardır. Toplamda 900 iç fındık görüntüsü kullanmışlardır. Renk özellikleri kullanılarak SVM, Bayes, Yapay sinir ağları ile sınıflandırmışlardır. Yapay sinir ağları ile %93,57 sınıflama doğruluğu elde etmişlerdir.

Keleş ve arkadaşları (2021) yaptıkları çalışmada, yapay sinir ağı ve diskriminant analizi kullanılarak fındık (*Corylus avellana* L.) çeşitlerinin sınıflandırmışlardır. 11 fındık çeşidinin fiziksel, mekanik ve optik özellikleri üç ana eksen için belirlenmiştir. Fiziksel, mekanik ve optik özellikler parametreleri bağımsız değişken olarak, fındık çeşitleri ise bağımlı değişken olarak dahil edilmiştir. Fındık çeşitlerini sınıflandırmak için üç eksenin her biri için modeller oluşturulmuştur. Yapay Sinir Ağları (YSA) ve diskriminant analizi (DA) ile sınıflandırma başarı oranları X eksen için %89,1 ve %92,7, Y eksen için %92,7 ve %92,7 ve Z eksen için %86,8 ve %88,7 olarak bulmuşlardır.

İkramullah K. ve Eros P. (2014) yaptıkları fındık için x-ray görüntülerinde özellik çıkarımı sınıflandırma ile fındık çeşitlerini sınıflandırmışlardır. Röntgen görüntü ile elde edilen 748 sağlıklı görüntü içermektedir. Fındık ürünleri, 20 hasarlı fındık ve 20 enfekte fındık resmi kullanılmıştır. Örneklerin %95'i sadece "iyi" kategorisine aittir. "Kötü" kategorisine %5 örnek bulunmuştur. Bu veriler için seçilmiş bozuk fındıkların tespiti için anormallik tespit algoritması kullanılmıştır.

Çizelge 1.1'de bu alanda yapılan akademik çalışmalar verilmiştir.

Çizelge 1.1 Fındık ve görüntü işleme üzerine yapılan çalışmalar

Sıra	Mahsul	Veri Parçaları	Sınıf	Metod	Kesinlik%	Referanslar
1	Hazelnut	2094	4	InceptionV3 , EfficientNet	97.85 99.28	(Kang ve Chen, 2020).
2	Hazelnut	50	3	Boostingyöntemi, Bagging yöntemi, DL4J	72 83 71	(Koç et al., 2020).
3	Hazelnut Kernel	2000	2	PLS-DA	92	(Giraud et al., 2018).
4	Hazelnut	300	3	SigmaScan®Pro 5.0	84	(Bayraktar et al., 2015).
5	Hazelnut	25	3	K-means,	90,100	(Solak ve Altınışık, 2018).
6	Hazelnut	40	11	Yapay Sinir Ağları (YSA) ve Diskriminant Analizi (DA)	X eksenini için 89,1 ve 92,7, Y eksenini için 92,7 ve 92,7 ve Z eksenini için 86,8 ve 88,7	(Keleş ve Taner, 2021).
7	Hazelnut	900	3	Yapay sinir ağları	93.57	(Güvenç et al., 2015).

Szegedy ve arkadaşları (2016) yaptıkları çalışmada evrişimli ağlarının, çok çeşitli görevler için en son teknoloji bilgisayarlı görü çözümlerinin merkezinde yer aldıklarını belirlemişlerdir. 2014'ten bu yana, çok derin evrişimli ağlar ana akım olmaya başladı ve çeşitli ölçülerde önemli kazanımlar sağladı. Artan model boyutu ve hesaplama maliyeti, çoğu görev için (eğitim için yeterli etiketli veri sağlandığı sürece) anında kalite kazanımlarına dönüşme eğiliminde olsa da hesaplama verimliliği ve düşük parametre sayısı, mobil görüş ve büyük gibi çeşitli kullanım durumları için hala etkinleştirici faktörlerdir.

Russakovsky ve arkadaşları (2018) yaptıkları çalışmada; Büyük ölçekli gerçek bilgi verileri toplamının zorluklarını tartışıyor, kategorik nesne tanımadaki önemli atılımları vurguluyor, büyük ölçekli görüntü sınıflandırma ve nesne algılama alanının mevcut durumunun ayrıntılı bir

analizini sağlıyor ve mevcut durumu karşılaştırıldığında bilgisayar verilerinin daha kesin olduğunu tespit etmiştir.

Iandola ve arkadaşları (2014) yaptıkları çalışmada; evrişimli Sinir Ağları (CNN'ler), doğru nesne sınıflandırması sağlayabilir. Yoğun veya seçilmiş önerilen nesne bölgelerini yineleyerek nesne algılama gerçekleştirmek için genişletilebilirler. Bununla birlikte, bu tür dedektörlerin çalışma süresi, görüntü başına incelenecek bölgelerin toplam sayısı ve/veya alanı olarak ölçeklenir ve bu tür dedektörlerin eğitimi engelleyici şekilde yavaş olabilir. Bununla birlikte, bazı CNN sınıflandırıcı topolojileri için, sınıflandırılacak örtüşen bölgeler arasında önemli işleri paylaşmak mümkündür.

Gupta ve arkadaşları (2022) yaptıkları çalışmada, derin öğrenme metotlarının tıbbi çalışmalarda uygulama alanlarının inceleyerek tıbbi tedavilerde derin öğrenme metotlarının gözle görülür faydalar sağladığını belirlemiştir.

Shorten ve arkadaşları (2019) yaptıkları çalışmada, derin evrişimli sinir ağlarının görüntü işleme görevlerinde iyi performans gösterdiği ancak büyük verilere bağımlı olduğu belirtilmektedir. Fazla uydurma sorunuyla karşılaşmamak için sınırlı veriye sahip uygulamalar için bir çözüm olarak veri büyütme üzerine odaklanmaktadır.

Engin GÜNEŞ (2022) yaptığı tez çalışmasında, oluşturduğu veri setinin %10'u kullanıldığında VGG16 sınıflandırma modeliyle başarıları %88, InceptionV3 modelinin başarılarını %72 ve Resnet50 modelinin başarıları da %56 olarak belirlemiştir.

Sun Z. ve arkadaşları (2020) yaptıkları çalışmada mısır, arpa, soya, şeker pancarı, yonca, buğday gibi ürünlerin sınıflandırma işlemi yaptıkları çalışmada %82'nin üzerinde bir başarı oranı elde etmişlerdir.

Basha C. Z. ve arkadaşları (2020) yağmurun fındık üzerindeki etkisini araştırmak ve olası zararlarını tahmin edebilmek için derin öğrenme metodu kullanarak tahmin algoritmaları geliştirmişlerdir.

Guillén Navarro M. A. ve arkadaşları (2020) özellikle fındık ürününde yıllık ürün kaybına ve ürünün kalitesine doğrudan etki eden don olayını tahmin edebilmek ve öncesinde gerekli

tedbirleri alınmasını sağlamak için derin yaptıkları çalışmada öğrenme metodunu kullanmışlardır.

Türkoğlu M. ve arkadaşları (2021) kayısı meyvesinin hastalıklarının tespit edilmesi ve sınıflandırılmasında derin öğrenme metodunu kullanmışlardır.

Derin öğrenme yaklaşımı kullanılarak yürütülen bir başka çalışmada Hossain M. S. ve arkadaşları (2018) yaptıkları çalışmada meyve çeşitlerinin sınıflandırılması üzerinde durmuşlar ve %99'dan fazla başarı sağlamışlardır.

Kang H. Ve Chen C. (2020) yaptıkları çalışmada derin öğrenme metodu kullanarak meyve üretim alanlarında gerçek zamanlı olarak elma meyvesinin tespitini %85 doğrulukta elde etmeyi başarmışlardır.

Caner K. ve arkadaşları (2020) fındık meyvesinin, sivri, kara ve tombul olarak türlerine göre sınıflandırılması işlemi yapmışlardır. Çalışmalarında makine öğrenimi ve derin öğrenme kullanarak sağlamışlar ve yüksek oranda başarı elde etmişlerdir.

Han Y. ve arkadaşları (2021) kuruyemiş türleri kullanarak yaptıkları çalışmada kuruyemiş kalite tahmininin üzerinde durmuşlar ve derin öğrenme metodu ile ortalama %95 başarı elde etmişlerdir.

Saranya ve arkadaşları (2020), elma, muz, portakal ve portakal için makine öğrenimi ve derin öğrenme algoritmaları kullanmıştır. Nar meyvesi sınıflandırmak için. R, G, B rengi, meyve boyu, boyu ve eni fiziksel özellikler olarak kullanılmıştır. Çalışmanın karşılaştırmalı sonuçları K-en yakın komşu için 49, destek vektör makinesi için 61 idi.

Öte yandan, evrişimli sinir ağı için sınıflandırma sistemi doğruluğu %97 olmuştur.

Kavdir ve Guyen (2003) yaptıkları çalışmada, elma sınıflandırması için bulanık mantık kullanmışlardır ve bulanık mantık uzman sistemi ile elde edilen sınıflandırma sonuçları %89 olmuştur.

Pronprasit ve Natwichai (2013) yaptıkları çalışmada NIR spektroskopisi ve topluluk sınıflandırması kullanılarak mango meyve kalitesinin tahmin edilmesi üzerinde durmuşlar ve

standart hatası önerilen topluluk sınıflandırıcı, naif topluluk sınıflandırıcı ve tek sınıflandırıcının tahmin değerleri 0.95, Sırasıyla 1.08 ve 0.99. Son araştırmalar, topluluk sınıflandırıcılarının değişen durumlarda iyi performans gösterebileceğinin belirtmişlerdir.

El-Bendary ve arkadaşları (2015) domates olgunluğunu 250 resim ile incelediler ve destek vektör makinelerine ek olarak temel bileşenler analizi (PCA) kullandılar. SVM'ler ve özellik çıkarma ve sınıflandırma için doğrusal diskriminant analizi (LDA) algoritmaları. Buldukları sonuçlar, doğrusal çekirdek işlevli SVM algoritması kullanılarak %85 doğruluk ve LDA kullanılarak %84 doğruluk göstermiş ve olgunluk sınıflandırması için algoritma. Sonuçlar LDA için %84, için %77 başarı elde etmişlerdir.

Manickavasagan ve arkadaşları (2017) Suudi Arabistan'ın çeşitli bölgelerinde yetiştirilen hurma çeşitlerine göre sınıflandırılmıştır. Kaliteyi belirlemek için kullanılan geleneksel pahalı ve zaman alan yöntemler yerine kullanarak yapay sinir ağı ve doğrusal diskriminant analiz yöntemleri geliştirmişlerdir. Kurutulmuş meyveleri sınıflandırmak için 1800 numunenin tek renkli görüntülerinden histogram ve doku özelliklerini çıkarmışlardır. Meyve türlerini yumuşak, yarı sert ve sert olarak sınıflandırdılar.

Miraei Ashtiani ve arkadaşları (2020) uzunluk, maksimum genişlik ve maksimum kalınlık gibi kabuk özelliklerinden yararlanılarak tahmini badem taneleri kütlesi hesaplamak için çalışma yapmışlar ve bu amaçla çok doğrusal çağrışım modeli, çok katmanlı algılayıcı sinir ağı, radyal tabanlı fonksiyon sinir ağı, uyarlanabilir nöro-bulanık çıkarım sistemi ve destek vektör makinesi algoritmaları kullanılmıştır. Sinirsel radyal temel fonksiyon kullanılarak badem tanelerinin kütlesi için yüksek genel doğruluk %96 olmuştur.

Vaishnav ve Rao (2018) 49 adet (elma, mango, kiraz, portakal ve ananas) Google'dan alınan meyve resimlerini sınıflandırma işlemi için lojistik regresyon, yapay sinir ağı, K en yakın komşu, karar ağacı, rastgele orman, naive bayes kullanılmışlar ve veri seti on kat çapraz doğrulama yöntemiyle çalıştırılmıştır. İlk set için lojistik regresyon %85 olarak tahmin edilmiş ve ikinci deney seti için %91 doğruluk sağlamışlardır.

Menesatti ve arkadaşları (2008) yaptıkları çalışma ile fındık çeşitlerini ayırt etmek için şekillendirilmiş tekniklerin potansiyel kullanmış ve %79 başarı elde etmişlerdir.

Wang ve Chen (2019) sekiz katmanlı bir CNN modeli oluşturmuşlar ve 18 meyve çeşidine ait olan 3600 görüntüyü %95,67 başarı ile sınıflandırmışlardır.

Zhu ve arkadaşları (2018) sebze görüntülerini sınıflandırmak için bir AlexNet ağ modeli kullanmışlar ve yazarlar, farklı veri kümeleri üzerinde CNN modellerini şu şekilde eğitmişlerdir: sebze görüntülerinin sayısını değiştirme, Sınıflandırma sonuçları, görüntü sayısı azaldıkça doğruluğun azaldığını göstermiştir. Ayrıca CNN tabanlı yöntemin doğruluk oranlarını geri yayımlı sinir ağı ile karşılaştırmışlardır.

Vijai ve arkadaşları (2017), bitki yaprak hastalıklarının otomatik tespiti ve sınıflandırılması için görüntü segmentasyonu için bir algoritma önerdiler. İlk aşamada Minimum Mesafe Kriteri ve K-Ortalamlar Kümeleme ile yapılan sınıflandırmada doğruluk %85,56'dır.

Mohanty (2016), derin öğrenme ve bilgisayar görüşü tabanlı bir yaklaşım geliştirdi. Toplam 54.306 adet hastalıklı ve sağlıklı bitki yaprağından oluşan veri seti halka sunulmuştur. 14 bitki türünü ve 26 hastalığı tespit etmek için derin bir sinir ağı eğitildi. Deneysel sonuçlar incelendiğinde eğitim modelinin %99,35 doğruluk sağladığı görülmüştür.

Zhang ve arkadaşları (2019), salatalık hastalığını tanımlamak için bir algoritma önerdiler. Küresel bir havuzlama, genişletilmiş evrişimli sinir ağı (GPDCNN)-AlexNet tabanlı yaklaşım. Model, hıyar yaprağı hastalıkları konusunda eğitilmiştir ve hıyar yaprağı hastalıklarını %95,65 doğrulukla tespit edilebilmektedir.


3.MATERYAL ve METOD

Bu bölümde, tez çalışmasında kullanılan veri setleri, uygulama araçları ve yöntemler ayrıntılı olarak açıklanmıştır. Araştırmanın bilimsel doğruluğunu ve tekrarlanabilirliğini sağlamak amacıyla, kullanılan teknolojik altyapı ve analiz süreçleri sistematik bir şekilde sunulmuştur. Çalışmada, derin öğrenme tabanlı sınıflandırma yöntemlerinin fındık çeşitleri üzerindeki uygulanabilirliği değerlendirilmiştir.

3.1 Veri Seti

Tez çalışması için gerekli olan fındıklar Türkiye'nin Karadeniz bölgesi Samsun İli Çarşamba ilçesi ve Ordu ili Gököy ilçesinden Ağustos ve Eylül aylarında toplanmıştır.

Yapılan bu çalışmada Türkiye'de yetiştirilen toplam sekiz adet fındık çeşidi kullanılmıştır. Bunlar; palaz, dağ, Foşa, tombul, hanımeli, çakıldak, kara fındık, sivri olarak sınıflandırılmaktadır. Yapılan bu çalışmada palaz fındıktan 150 adet, dağ fındığından 320 adet, Foşa fındıktan 380 adet, tombul fındıktan 230 adet, hanımeli fındıktan 380 adet, çakıldak fındıktan 320 adet, kara fındıktan 420 adet ve sivri fındıktan 390 Adet görüntü olmak üzere toplam 2590 adet görüntüyle çalışılmıştır. Aşağıdaki grafikte kullanılan resimler ve fındık türleri belirtilmiştir.



Şekil 3.1 Kullanılan fındık türleri ve sayıları

Bu görüntüler Şekil 3.3 de verilen düzenek yardımı ile çekilmiştir. Görüntüler 3088x3088 boyutunda renkli ve jpg formatındadır. Resimler, f1,9 diyafram açıklığı ISO40 hassasiyeti ile flaşsız olarak çekilmiştir.

Görüntüler, 13 megapiksel çözünürlüğe sahip Samsung Galaxy A02 dijital kamera kullanılarak 10 cm mesafeden çekilmiştir.




Şekil 3.2 Çalışmada kullanılan Fındık Türleri.

Araştırmamızda fındık imajlarını almak için kullandığımız düzenek dört tarafı kapalı ve üst kısmında aydınlatma sistemi olan bir düzendir. Dört tarafı kapalı olması sayesinde dışarıdan ışık kaynağı haricinde ışık almayarak örnek fındık türlerinin daha net fotoğraflarının çekilmesi sağlanmıştır.

3.2 Görüntü Elde Edilmesi

Çalışmamızda kullanılan fındık ürünlerinin görüntüleri kapalı kutu mekanizması kullanılarak elde edilmiştir. Bu mekanizmada dört tarafı kapalı bir kutu ve üzerinde bir aydınlatma sistemi bulunmaktadır. Aydınlatma sisteminin ortasında bulunan kamera sayesinde görüntüler elde edilmektedir. Kutunun dört tarafının kapalı olmasının sebebi etraftan gelen ışıktan kutunun içindeki fındık görüntüsünü koruyarak gölgelenme olmasının engellemektir. Görüntüler kamera aracılığıyla sabit bir depolama aracına aktarılarak elde edilmiştir. Görüntüleme sırasında görüntülerin net şekilde elde edilmesi için beyaz zemin kullanılmıştır.

Derin öğrenme fındık ürünü materyallerinin sisteme aktarılmasında kullanılan düzenek şekil 3.3'te gösterilmiştir.



Şekil 3.3 Fındık görüntülerinin elde edilmesinde kullanılan düzenek.

Görüntülerin elde edilmesi için belirli bir akış şeması oluşturulmuş ve çalışmada bu akış şemasına uygun veriler elde edilerek derlenmiştir.

3.3 Görüntülerin Ön İşlemden Geçirilmesi


Görüntü ön işleme yapılması çalışmada kullanılacak görüntülerin değerlendirme ve sonuç işlemi yapılmadan önce görüntülerin kalitesini artırmak ve verilerin tutarlılığını sağlamak

amacıyla yapılan işlemler bütünüdür. Görüntülerin ön işlemden gerilmesinin bazı aşamaları şunlardır; Görüntülerin yeniden boyutlandırılması ve ölçekleme yapılması, renk alanlarının değiştirilmesi, görüntü eksiltme yapılması, parlaklık ayarlarının yapılması, piksel değerlerinin ölçeklendirilmesi, veri artırma, filtreleme, geometrik ayarların yapılması, kesme işlemi.

3.3.1 Veri artırımı

"Veri artırımı" (data augmentation), bir makine öğrenmesi veya derin öğrenme modelinin eğitimi için kullanılan bir tekniktir. Veri artırımı, mevcut veri kümesindeki örnekleri değiştirerek veya yeni örnekler üreterek, öğrenme modelinin daha iyi genelleme yapmasına ve daha iyi performans göstermesine yardımcı olur.

Veri artırımı teknikleri, görüntü, ses, metin ve diğer türdeki verileri işleyen modellerde kullanılabilir. Örneğin, görüntü verileri için veri artırımı teknikleri, görüntüleri çevirme, kesme, döndürme, yansıtma, renk düzeltme veya gürültü ekleme gibi işlemlerle mevcut veri kümesini genişletebilir. Metin verileri için ise, kelime değiştirme, kelime sırasını değiştirme, cümle çevirme veya ekleme, sözcükler arasındaki ilişkileri değiştirme gibi teknikler kullanılabilir (Ferentinos, 2018). Şekil 3,4'da veri artırma örneği verilmiştir.



Şekil 3.4 Veri artırma (Engati Portalı, 2025).

Veri artırma, makine öğreniminde, özellikle derin sinir ağlarının eğitiminde, mevcut verilere çeşitli dönüşümler uygulayarak veri kümesinin boyutunu yapay olarak artırmak için kullanılan bir tekniktir. Veri artırmanın amacı, eğitim setinin çeşitliliğini arttırmaktır; bu da daha iyi genelleme ve gelişmiş model performansına yol açabilir. Bu teknik özellikle eğitim için mevcut etiketli verilerin sınırlı olduğu durumlarda değerlidir.

3.3.2 Yaygın veri artırma teknikleri şunları içerir

Döndürme: Değişkenlik sağlamak için görüntülerin belirli bir dereceye kadar döndürülmesi (örneğin, belirli bir aralıkta rastgele döndürme).

Çevir (Yatay veya Dikey): Farklı bakış açılarını simüle etmek için görüntüleri yatay veya dikey olarak çevirme.

Ölçeklendirme: Nesne boyutlarına çeşitlilik katmak için görüntüleri yakınlaştırıp uzaklaştırarak yeniden boyutlandırma.

Çeviri: Nesnenin çerçeve içindeki konumundaki değişiklikleri simüle etmek için görüntüleri yatay veya dikey olarak kaydırmak.

Kesme: Verileri eksenlerden biri boyunca uzatmak veya sıkıştırmak için kesme dönüşümleri uygulama.

Yakınlaştırma: Bir görüntünün belirli bölgelerine rastgele yakınlaştırma.

Renk Titreşimi: Görüntülerin renginde parlaklık, karşıtlık, doygunluk veya renk tonu ayarlamaları gibi rastgele değişiklikler yapılması.

Gürültü Ekleme: Modeli gerçek dünya senaryolarında gürültüye karşı daha dayanıklı hale getirmek için verilere rastgele gürültü eklemek.

Veri artırma genellikle eğitim aşamasında uygulanır ve modeli bir doğrulama veya test seti üzerinde değerlendirirken kullanılmaz. Artırılmış veriler, eğitim setinin çeşitliliğini etkili bir

şekilde artırarak modelin daha sağlam özellikler öğrenmesine yardımcı olur ve orijinal veri setinde mevcut sınırlı varyasyonlara aşırı uyum riskini azaltır.

Görüntü sınıflandırma veya nesne tespiti gibi bilgisayarlı görme görevlerinde, evrişimli sinir ağlarının (CNN'ler) performansını artırmak için veri artırma yaygın olarak kullanılır. Artırılmış veriler, modelin girdi verilerindeki farklı dönüşümlere ve varyasyonlara karşı daha değişmez hale gelmesini sağlayarak, gerçek dünya senaryolarına uygulandığında daha iyi genelleme yapılmasına olanak sağlar.

Bu teknikler, veri setlerinin boyutunu artırarak modelin daha fazla çeşitlilikle karşılaşmasına ve daha iyi performans göstermesine yardımcı olabilir. Ancak, bazı durumlarda, veri artırımı aynı zamanda veri setindeki örneklerin çoğaltılması veya benzer örneklerin oluşturulması nedeniyle aşırı uydurma (overfitting) sorununa da neden olabilir (Szegedy et al., 2016).

Bu kullanılan veri artırma teknikleri, içinde bulunan şekil bilgilerinden çok renk ve doku bilgileri ile yapılan analizlerde öne çıkan fındık görüntülerinde etkili olmamaktadır. Bu nedenle, veri artırımı klasik yöntemlerin yerine yüksek çözünürlüklü ve yüksek boyuttaki fındık görüntülerinden, her bir erişimsel sinir ağı (ESA) mimarisinin girdi boyutlarına uygun adaptif yeni görüntüler oluşturulmuştur.

Tez çalışmamızda Çizelge 3.1’de verilen veri artırma teknikleri kullanılmıştır.

Çizelge 3.1 Artırma teknikleri ve aralıkları

Artırma tekniği	Değer
Rotasyon	40
Genişlik kaydırma	0,2
Yükseklik kaydırma	0,2
Paylaşım	0,2
Odaklama	0,2
Yatay çevirme	True
Doldurma modu	Nearest

Her bir fındık görüntüsü 40 derecelik döndürme işlemine tabi tutulmuş, genişlik kaydırma değeri 0,2, yükseklik kaydırma değeri 0,2, paylaşım değeri 0,2, odaklama değeri 0,2, yatay çevirme değeri True, doldurma modu Nearest olarak kullanılmıştır.

Tez çalışmasında kullanılan fındık görüntüleri, daha iyi ve verimli sonuçlar elde edebilmek amacıyla veri artırma yöntemi uygulanarak çoğaltılmıştır. Çalışmada hem çoğaltılmış veriler hem de orijinal veriler kullanılarak geliştirilen yöntemler uygulanmış ve elde edilen bulgular sonuçlar bölümünde ayrıntılı bir şekilde sunulmuştur.

Çizelge 3.2 Artırma öncesi ve sonrası görüntü sayıları.


Fındık Türleri	Orjinal Görüntü sayısı	Veri Artırma Sonrası sayı
Palaz	150	750
Dağ	320	750
Foşa	380	750
Tombul	230	750
Hanımeli	380	750
Çakıldak	320	750
Kara Fındık	420	750
Sivri Fındık	390	750

3.4 Önerilen Model

Önerilen fındık türlerinin sınıflandırılmasına yönelik derin öğrenme modeli, temel olarak dört ana katmandan oluşmaktadır: fındık veri setinin oluşturulması, görüntü işleme işlemleri, eğitim verilerinin hazırlanması ve transfer öğrenme modellerinin uygulanması. Bu çalışmada, 8 farklı fındık türüne ait toplam 2590 görüntü elde edilerek bir fındık veri seti oluşturulmuştur. Görüntüler üzerinde herhangi bir ön işleme veya doğrulama işlemi gerçekleştirilmeden, doğrudan yapay sinir ağına aktarılmıştır.


Çalışmanın uygulama aşaması, Google Colab platformunda gerçekleştirilmiş olup, deneyler NVIDIA T4 grafik işlemcisine (GPU) ve 16 GB RAM'e sahip bir çalışma ortamında Python programlama dili kullanılarak yürütülmüştür.

Önerilen modelde, fındık görüntülerinin başarılı bir şekilde sınıflandırılması amacıyla derin öğrenme tabanlı maskeli evrişimsel sinir ağı (CNN) modelleri kullanılmıştır. Bu modeller, koordinatlara ait sınıflandırmaların yapılmasında etkili olmuş ve her bir görüntüye ait özelliklerin kullanılması sayesinde yüksek doğruluk oranlarına ulaşılmıştır.



Şekil 3.6 Kullanılan yapıya ait şema.

Veri oluşturma sistemimiz, sırasıyla görüntü elde edilmesi, veri boyutlarının yeterliliğinin değerlendirilmesi, görüntü etiketlerinin atanması ve veri setinin uygunluğunun belirlenmesi adımlarından oluşmaktadır. Veri boyutlarının uygun olmaması durumunda yeniden boyutlandırma işlemi yapılmakta, veri seti sayısının yetersiz olması halinde ise veri artırma yöntemleri uygulanmaktadır. Bu süreçte kullanılan veri hazırlama şeması, Şekil 3.7’de sunulmuştur.




Şekil 3.7 Veri hazırlama şeması.

3.5 Yapay Sinir Ağları (YSA)

Yapay sinir ağları (YSA), biyolojik sinir sistemlerinden esinlenerek oluşturulan bir makine öğrenme yöntemidir. YSA'lar, büyük miktardaki verileri işleyebilen, desenleri tanıyabilen ve tahminler yapabilen bir yapay zekâ modelidir.

YSA'lar, bir dizi yapay sinir hücresi ve "nöron" den oluşur. Her bir nöron, girdi verilerini alır, bu verileri ağırlıklarını kullanarak çarpan haline getirir ve aktivasyon fonksiyonu ile çıktı üretir. Bu nöronlar, katmanlar halinde düzenlenmiştir. Giriş katmanı, verileri alır ve ardışık katmanlarda işler. Her katmandaki nöronlar, önceki katmandaki nöronlardan aldıkları çıktıları girdi olarak kullanır (Ucuza, 2020). Şekil 3,8'de Yapay sinir ağı örneği verilmiştir.




Şekil 3.8 Yapay sinir ağı (Aoyılmaz Portalı,2025).

Yapay Sinir Ağı (YSA), insan beynindeki biyolojik sinir ağlarının yapısından ve işleyişinden ilham alan hesaplamalı bir modeldir. Makine öğreniminin önemli bir bileşenidir ve daha özellikli olarak, birden fazla katman kullanıldığında daha geniş bir derin öğrenme kategorisine girer. YSA'lar örüntü tanıma, sınıflandırma, çağrışım ve karar verme gibi çeşitli görevler için kullanılır (Ucuzal, 2020).

Yapay sinir ağının temel bileşenleri şunlardır:

Nöronlar (Düğümmler): Nöronlar bir yapay sinir ağının temel birimleridir. Her nöron bir veya daha fazla girdi alır, bunları ağırlıklı toplam kullanarak işler, bir aktivasyon fonksiyonu uygular ve bir çıktı üretir. Daha sonra bir nöronun çıktısı diğer nöronlara girdi olarak aktarılır. Şekil 3.9'de İnsan beyni nöron yapısı ve yapay zekâ nöron yapısı karşılaştırması verilmiştir.



Şekil 3.9 İnsan beyni nöron yapısı ve yapay zekâ nöron yapısı karşılaştırması (Hackernoon Portali,2025).

Bağlantılar (Kenarlar veya Ağırlıklar): Bağlantılar, nöronlar arasındaki yolları temsil eder. Her bağlantı, bağlantının gücünü belirleyen bir ağırlıkla ilişkilendirilir. Ağın verilerden öğrenmesini sağlamak için ağırlıklar eğitim süreci sırasında ayarlanır.

Katmanlar: Nöronlar yapay sinir ağlarında katmanlar halinde düzenlenir. Üç ana katman türü şunlardır:

Giriş Katmanı: İlk giriş verilerini alır.

Gizli Katmanlar: Giriş ve çıkış katmanları arasında işlem ve öğrenmenin gerçekleştiği ara katmanlardır. Birden fazla gizli katmana sahip ağlara derin sinir ağları adı verilmektedir.

Çıkış Katmanı: İşlenen bilgilere dayanarak ağın son çıktısını üretir.


Aktivasyon Fonksiyonu: Her nöron tipik olarak ağa doğrusal olmamayı sağlamak için ağırlıklı girdi toplamına bir aktivasyon fonksiyonu uygular. Yaygın aktivasyon fonksiyonları arasında sigmoid, hiperbolik tanjant (tanh) ve düzeltilmiş doğrusal birim (ReLU) bulunur.

İleri Besleme ve Geri Yayılım: Eğitim süreci sırasında ağ ileri besleme ve geri yayılımdan geçer. İleri besleme, bir çıktı üretmek için girdinin ağ üzerinden iletilmesini içerirken geri yayılma, tahmin edilen çıktı ile gerçek hedef değerler arasındaki farka dayalı olarak ağırlıkları ayarlar.

Yapay sinir ağları, görüntü ve konuşma tanıma, doğal dil işleme ve finansal tahmin gibi çok çeşitli görevlere uygulanabilir. Verilerden öğrenme ve karmaşık kalıplara uyum sağlama yeteneği, sinir ağlarını makine öğrenimi ve yapay zekâda güçlü araçlar haline getirir. Görüntüyle ilgili görevler için evrişimli sinir ağları (CNN'ler) veya sıralı veriler için tekrarlayan sinir ağları (RNN'ler) gibi farklı mimariler, belirli sorun türlerine göre uyarlanmış temel sinir ağı yapısının varyasyonlarıdır (Çataloluk, 2012).


YSA'lar, eğitim sürecinde verileri kullanarak ağırlıkları öğrenirler. İlk başta rastgele başlangıç ağırlıklarıyla başlarlar ve ardından veriler üzerinde tekrar tekrar iterasyonlar yaparak ağırlıkları ayarlarlar. Bu iterasyonlar sırasında, ağ çıktıları gerçek sonuçlarla karşılaştırılır ve bir hata fonksiyonu kullanılarak hatanın ölçülmesi sağlanır. Ardından, hata geriye doğru yayılır ve ağırlıkların ayarlanması için bir en uygun şekle sokma algoritması kullanılır. Bu süreç, ağın daha iyi sonuçlar üretmek için veriye uyum sağlamasını sağlar.

Yapay sinir ağları, karmaşık veri modellerini oluşturabilme yetenekleri ve geniş veri kümeleri üzerinde yüksek performans sağlayabilme potansiyeli nedeniyle birçok uygulama alanında kullanılmaktadır. Bunlar arasında görüntü ve konuşma tanıma, otomatik sürüş teknolojileri, doğal dil işleme, finansal tahminler ve tıbbi teşhis gibi birçok alanda kullanımı bulunmaktadır (Çataloluk, 2012). Şekil 3.10 Yapay sinir ağları (YSA) örneği verilmiştir.



Şekil 3.10 Yapay sinir ağları (YSA) (Xiong et al., 2021).

Çok çeşitli yapay sinir ağları mevcuttur. Çok farklı görevler için geliştirilmiş yapay sinir ağı çeşitleri Şekil X.Y 'de verilmiştir.




Şekil 3.5 Network Sinir Ağları Örnekleri (Devnot Portalı,2025).

3.6 Derin Öğrenme

Derin öğrenme, yapay sinir ağları gibi karmaşık matematiksel modeller kullanarak bilgisayarların, büyük veri kümelerinden öğrenme yeteneğini ifade eder.

Makine öğreniminin, büyük veri teknolojilerinin ve yüksek performanslı bilgi işlemin ortaya çıkışı, çok disiplinli tarımsal çalışmalarda yeni fırsatlar sağlamıştır (Karakuçuk ve Eker, 2020).

Derin öğrenme, yapay sinir ağlarının, özellikle derin sinir ağlarının geliştirilmesine ve uygulanmasına odaklanan makine öğreniminin bir alt alanıdır. "Derin" terimi, sinir ağlarında çoklu katmanların (derin mimariler) kullanımını ifade eder. Bu derin mimariler, verilerdeki karmaşık hiyerarşik kalıpları öğrenme ve temsil etme yeteneğine sahiptir (Karakuçuk ve Eker, 2020). Şekil 3.11'de Derin öğrenme şeması verilmiştir.




ITERATORS
Source: www.iteratorshq.com

Şekil 3.11 Derin öğrenme şeması (Coderspace Portalı,2025).

Derin öğrenmenin temel kavramları ve özellikleri şunları içerir:

Sinir ağıları: Derin öğrenme, insan beyninin yapısından ve işlevinden ilham alan hesaplamalı modeller olan yapay sinir ağlarına dayanmaktadır. Sinir ağıları, katmanlar halinde düzenlenmiş birbirine bağlı düğümlerden oluşur. Girdi verileri, bir çıktı üretmek için bu katmanlar aracılığıyla işlenir; ağırlıkların ayarlanması yoluyla girdileri istenen çıktılarla yan yana sınıflamayı öğrenir. Şekil 3.12’de Yapay sinir ağı örneği verilmiştir.




Şekil 3.12 Yapay Sinir Ağı Örneği (Dergipark Portalı, 2025).

Derin mimariler: Derin öğrenme modelleri genellikle birden fazla katmana sahiptir ve verilerin hiyerarşik temsillerini otomatik olarak öğrenmelerine olanak tanır. Bu derin mimariler, karmaşık özelliklerin ham girdiden çıkarılmasına olanak tanıyarak bunları görüntü tanıma, doğal dil işleme ve konuşma tanıma gibi görevlere uygun hale getirir.

Temsil öğrenme: Derin öğrenme, ağıdaki her katmanın farklı soyutlama seviyelerindeki özellikleri çıkardığı, verilerin hiyerarşik temsillerini öğrenmeye odaklanır. İlgili özellikleri otomatik olarak öğrenme yeteneği, derin öğrenmeyi özellikle büyük ve karmaşık veri kümelerine sahip görevler için etkili kılar.

Uçtan uca öğrenme: Derin öğrenme modelleri, ham girdiden çıktıya kadar uçtan uca eşlemeleri öğrenmek için tasarlanmıştır. Bu, modelin, ara gösterimleri veya özellikleri açıkça elle

işlemeden özellik çıkarma, özellik dönüştürme ve karar almayı otomatik olarak öğrenebileceği anlamına gelir. Şekil 3.13’de Uçtan Uca Öğrenme örneği verilmiştir.



Şekil 3.13 Uçtan uca öğrenme (Resarchgate Portalı, 2025).

Geri Yayımlı Eğitim: Derin öğrenme modelleri, tahmin edilen ve gerçek çıktılar arasındaki hataya göre sinir ağının ağırlıklarını ayarlayan geri yayılım algoritması kullanılarak eğitilir. Bu yinelemeli en uygun şekle sokma süreci, modelin zaman içinde performansını artırmasına yardımcı olur.

Uygulamalar: Derin öğrenme, görüntü ve konuşma tanıma, doğal dil işleme, otonom araçlar, tıbbi teşhis ve diğerleri dâhil olmak üzere çeşitli uygulamalarda dikkate değer bir başarı elde etmiştir. Belirli alanlarda geleneksel makine öğrenimi yöntemlerini geride bırakarak çok sayıda görev için performansta yeni ölçütler belirlemiştir.

Popüler derin öğrenme mimarileri arasında görüntüyle ilgili görevler için Evrişimli Sinir Ağları (CNN'ler), sıra verileri için Tekrarlayan Sinir Ağları (RNN'ler) ve doğal dil işleme görevleri için Transformer mimarileri bulunur.

Derin öğrenme, yapay zekada baskın bir paradigma haline gelmiş; çeşitli endüstrilerdeki gelişmelere yön verdi ve bilgisayar görüşü, konuşma tanıma ve doğal dil anlayışı gibi alanlarda atılımlara katkıda bulunmuştur (Huang et al., 2017). Şekil 3.14’de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki verilmiştir.




Şekil 3.14 Derin öğrenme, makine öğrenmesi ve yapay zekâ ilişkisi.

Derin öğrenme, geniş ve karmaşık veri kümeleri üzerinde, örneğin birçok görüntü veya metin belgesi gibi, katmanlar halinde işlem yaparak özellikleri tanımlamak ve öğrenmek için kullanılır. Bu katmanlar, verinin farklı yönlerini işleyen, sıralı bir dizi matematiksel işlemlerden oluşur. Bu işlemler sayesinde, yapay sinir ağları, veri kümelerindeki desenleri ve ilişkileri keşfedebilir, özelliklerini çıkarabilir ve tahminlerde bulunabilir (Huang et al, 2017).

Derin öğrenme algoritmaları, büyük miktarda veriyi işleyerek kendilerini eğitir ve sonuçta bu veriler üzerinde doğru sonuçlar vermek için gerekli olan parametreleri otomatik olarak ayarlar. Bu sayede, örneğin görüntü tanıma, doğal dil işleme ve oyun oynama gibi pek çok farklı alanda insanların yaptığı işlemleri gerçekleştirebilen sistemler oluşturulabilir (Huang et al, 2017).

Derin öğrenme, günümüzde pek çok farklı alanda kullanılmaktadır. Örneğin, görüntü işleme, ses tanıma, otomatik çeviri, reklam önerisi, sürücüsüz araç teknolojisi gibi birçok alanda kullanılmaktadır.


Derin öğrenme algoritmaları, verilerin giriş katmanına verildiği ve sonuçların çıkış katmanından elde edildiği çok katmanlı yapay sinir ağları kullanır. Veriler, ağın giriş katmanındaki nöronlara verilir ve ardından ağın katmanları boyunca işlenir. Her katmanda, girdi verileri işlenerek yeni özellikler elde edilir ve çıkış katmanına doğru ilerlenir. Çıkış katmanında, ağın öğrenmiş olduğu bilgilere dayanarak bir sonuç üretilir (Shorten ve Khoshgoftaar, 2019). Şekil 3.15'te Aktarılan bilginin biçimine göre düzenlenen farklı aktarımla öğrenme yaklaşımları gösterilmiştir.



Şekil 3.15 Aktarılan bilginin biçimine göre düzenlenen farklı aktarımla öğrenme yaklaşımları (Zhu et al., 2020).

3.7 Transfer Öğrenme

Transfer öğrenme, özellikle makine öğrenimi ve yapay zekâ alanlarında önemli bir kavramdır. Bu alanlarda, bir modelin bir görevi öğrenmesi için birçok veri örneği gerektiği düşünülür. Ancak, her görev için ayrı ayrı model eğitmek çok zahmetli ve zaman alıcı olabilir. Bu nedenle, daha önce öğrenilen görevlerden elde edilen bilgi ve beceriler, yeni görevleri öğrenmek için kullanılabilir (Keleş ve Taner, 2021). Şekil 3.16'te Örnek transfer öğrenme şeması gösterilmiştir.



Şekil 3.16 Örnek Transfer Öğrenme Şeması (Dergipark Portalı, 2025).

Transfer öğrenimi, bir görev üzerinde eğitilen modelin ikinci, ilgili göreve uyarlandığı bir makine öğrenme tekniğidir. Hedef görev için sıfırdan bir model eğitmek yerine, transfer öğrenimi, potansiyel olarak farklı ancak ilgili bir veri kümesi ile kaynak görevden elde edilen bilgiden yararlanır. Model, daha büyük bir kaynak veri kümesi üzerinde eğitim sırasında edinilen bilgilerden yararlanabileceğinden, bu yaklaşım özellikle hedef görevin sınırlı etiketli veriye sahip olduğu durumlarda faydalıdır (Keleş ve Taner, 2021).

Transfer öğrenimde genellikle iki ana senaryo vardır:

Özellik çıkarma (temsil öğrenme): Bu senaryoda, genellikle belirli bir görev için büyük bir veri kümesi üzerinde eğitilmiş, önceden eğitilmiş bir model, özellik çıkarıcı olarak kullanılır. Modelin önceki katmanlarından öğrenilen gösterimler veya özellikler daha sonra daha küçük bir veri kümesi ile hedef görev üzerinde eğitilen yeni bir modele beslenir. Buradaki fikir, önceden eğitilmiş modelin alt katmanlarının, çok çeşitli görevler için değerli olabilecek genel özellikleri öğrenmiş olmasıdır.

İnce ayar (Adaptasyon): İnce ayarda, önceden eğitilmiş model, daha küçük bir veri kümesi ile hedef görev üzerinde daha da eğitilir. Modelin alt katmanları genellikle dondurulurken (kaynak görevden öğrenilen genel özellikleri korumak için), daha yüksek katmanlar hedef görevin

özelliklerine uyum sağlayacak şekilde değiştirilir ve yeniden eğitilir. Bu, modelin yeni veri kümesindeki nüanslarda uzmanlaşmasına olanak tanır.

Transfer öğrenimi, bilgisayarlı görme, doğal dil işleme ve konuşma tanıma dâhil olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır. Yaygın senaryolar şunları içerir:

Görüntü sınıflandırma: ImageNet veri kümesindekiler gibi önceden eğitilmiş modeller genellikle yeni görüntü sınıflandırma görevleri için özellik çıkarıcı olarak kullanılır.

Doğal dil işleme (NLP): Çok miktarda metin verisi üzerinde önceden eğitilmiş BERT veya GPT gibi dil modelleri, duygu analizi veya metin sınıflandırma gibi belirli NLP görevleri için ince ayar yapılabilir.

Nesne algılama: Nesne algılama görevleri için büyük veri kümeleri üzerinde önceden eğitilmiş modeller, daha küçük veri kümeleriyle belirli nesne algılama zorlukları için ince ayar yapılabilir.

Transfer öğrenimi, ilgili görevlerden elde edilen bilgilerden yararlanarak sınırlı etiketli verilerden kaynaklanan zorlukların üstesinden gelmeye yardımcı olur. Özellikle hedef görev için büyük miktarlarda etiketli veri toplamanın pratik olmadığı veya pahalı olabileceği senaryolarda, modellerin performansını artırmak için etkili bir strateji olduğu kanıtlanmıştır (Köklü et al., 2022).

Transfer öğrenimi, önceden eğitilmiş bir modelin ilgili bir görevde yeniden kullanılmasını içeren bir makine öğrenimi tekniğidir. Bir modeli sıfırdan eğitmek yerine, aktarım öğrenimi büyük bir veri kümesi üzerinde eğitilmiş mevcut bir modelle başlar ve onu belirli bir görev veya sorun için ince ayar yapar.

Transfer öğrenimi, bilgisayar görüşü, doğal dil işleme ve konuşma tanıma gibi çeşitli alanlarda uygulanabilir. Makine öğreniminde, özellikle etiketli veri miktarının sınırlı olduğu veya sıfırdan yeni bir model eğitiminin hesaplama açısından pahalı olduğu senaryolarda popüler bir teknik haline geldi (Köklü et al, 2022).

Kesinlikle! Transfer öğrenimi, onu makine öğrenimi ve derin öğrenmede güçlü bir teknik haline getiren çeşitli avantajlar sunar:

Veri verimliliği: Transfer öğrenimi, hedef görev için sınırlı etiketli veri mevcut olduğunda özellikle faydalıdır. Önceden eğitilmiş modellerden ve büyük veri kümesine sahip bir kaynak görevden elde edilen bilgilerden yararlanılarak model, daha az miktarda etiketli veriyle hedef görevde daha iyi performans elde edebilir.

Daha hızlı eğitim: Büyük bir veri kümesi üzerinde derin bir sinir ağını sıfırdan eğitmek, hesaplama açısından pahalı ve zaman alıcı olabilir. Transfer öğrenimi, ilk katmanların genel özellikleri zaten öğrenmiş olması nedeniyle hedef görevde modelin daha hızlı yakınsamasına olanak tanır.

Genelleme: Önceden eğitilmiş modeller, verilerin yararlı temsillerini yakalar ve genellikle görevler arasında aktarılabilen hiyerarşik özellikleri öğrenir. Bu genel özellikler, modelin hedef görev için yeni, görülmemiş verilere iyi bir şekilde genellenmesine yardımcı olur.

Etki alanı uyarlaması: Aktarım öğrenimi, kaynak ve hedef görevlerin farklı ancak ilişkili alanlara sahip olduğu senaryolarda değerlidir. Önceden eğitilmiş model, öğrenilen özellikleri hedef alana uyarlayarak kapsamlı yeniden eğitim ihtiyacını azaltabilir.


Göreve özel uyarlama: İnce ayar, önceden eğitilmiş bir modelin göreve özel uyarlanmasına olanak tanır. Ağı daha yüksek katmanlarını ayarlayarak model, kaynak görevden gelen bilgiyi korurken hedef görevin karmaşıklıkları konusunda uzmanlaşabilir.

Modelin yeniden kullanılabilirliği: Önceden eğitilmiş modeller, aynı etki alanındaki çeşitli görevler için değerli başlangıç noktaları olarak hizmet edebilir. Uygulayıcılar, her yeni görev için sıfırdan modeller oluşturmak yerine mevcut modelleri temel olarak kullanabilir ve gerektiğinde bunları özelleştirilebilir.

Faydalarına rağmen transfer öğrenimi, kaynak ve hedef görevlerin bilgi aktarımı için yeterince ilişkili olmasını sağlamak ve aşırı uyumu önlemek için uyarlama sürecini dikkatli bir şekilde yönetmek gibi hususları da beraberinde getirir.

Genel olarak transfer öğrenimi, birçok makine öğrenimi uygulamasında standart bir uygulama haline geldi ve gelişmiş model performansına, verimliliğe ve sınırlı etiketli verilerle gerçek dünyadaki zorlukları çözme becerisine katkıda bulundu. Araştırmacılar ve uygulayıcılar çeşitli

görevler ve alanlar için transfer öğrenme tekniklerini keşfetmeye ve iyileştirmeye devam ediyor (Köklü et al, 2022). Şekil 3.17’te transfer öğrenme modeli gösterilmiştir.




Şekil 3.17 Transfer Öğrenme.

3.8 DenseNet121 Modeli

Dense Convolutional Network'ün kısaltması olan DenseNet, 2017'de Cornell Üniversitesi'nden Gao Huang, Zhuang Liu ve Kilian Q. Weinberger tarafından tanıtılan evrişimli bir sinir ağı mimarisidir.

DenseNet, her katmanı diğer tüm katmanlara ileri beslemeli bir şekilde yoğun bir şekilde bağlama fikrine dayanmaktadır. Bir Yoğun Ağda, her katman önceki tüm katmanların özellik haritalarını girdi olarak alır ve kendi özellik haritaları sonraki tüm katmanlara aktarılır. Bu, katmanların birbiri ardına sırayla bağlandığı geleneksel evrişimli sinir ağlarının tersidir (Cinar et al., 2022). Şekil 3.18’te DenseBlock, convblock ve geçiş katmanı gösterilmiştir.



Şekil 3.18 DenseBlock, convblock ve geçiş katmanı (Zhang et al., 2021).

DenseNet-121, DenseNet serisinin bir parçasıdır ve özellikle 121 katmanlı bir varyantı ifade eder. DenseNet mimarisi, çeşitli nedenlerden dolayı derin öğrenme topluluğunda iyi karşılanmıştır: Parametre Verimliliği: Yoğun bağlantı, özelliklerin yeniden kullanımını kolaylaştırır; bu, her katmanın, önceki tüm katmanlar tarafından çıkarılan özelliklere erişebileceği anlamına gelir. Bu, öğrenilen özelliklerin fazlalığını azaltır ve parametre açısından daha verimli modellere yol açar.

Gradyan Akışı: Yoğun bağlantılar, geri yayılım sırasında gradyanlar için daha kısa yollar oluşturur. Bu, yok olan gradyan probleminin hafifletilmesine yardımcı olur ve derin ağların daha etkili bir şekilde eğitilmesine olanak sağlar.

Geliştirilmiş Özellik Yayılımı: Yoğun bağlantı, özelliklerin ağ üzerinden daha doğrudan yayılmasına olanak tanır. Bu, modelin hem düşük seviyeli hem de yüksek seviyeli özellikleri yakalama yeteneğini geliştirerek temsil gücünün artmasına yol açabilir.

Aşırı Uyumun Azaltılması: Darboğaz katmanlarındaki yoğun bağlantı ve parametrelerin azaltılması, bir tür örtülü düzenlemeye katkıda bulunarak aşırı uyumun azaltılmasına ve genellemenin iyileştirilmesine yardımcı olur.

Eğitim Kolaylığı: DenseNet mimarileri nispeten basit eğitim prosedürleri ile tanınır. Katmanlar arasındaki yoğun bağlantı ve atlama bağlantıları, istikrarlı eğitim dinamiklerine katkıda bulunur.

DenseNet-121 veya diğer DenseNet varyantlarını belirli görevlere uygularken, ImageNet gibi büyük veri kümelerinde önceden eğitilmiş modellerin kullanılması yaygındır. Önceden eğitilmiş modellerle aktarım öğrenimi, potansiyel olarak sınırlı verilerle farklı ancak ilgili bir görevde performansı artırmak için bir görevden elde edilen bilgilerden yararlanmaya olanak tanır.

Genel olarak DenseNet-121, derin öğrenme alanındaki çeşitli görevlerde etkinliğini sergileyerek görüntü sınıflandırma, nesne algılama ve segmentasyon dâhil olmak üzere çeşitli bilgisayarlı görme uygulamalarında popüler bir seçim haline geldi.

DenseNet, her biri birden çok katmandan oluşan yoğun bloklardan oluşur. Her yoğun blok içinde, önceki tüm katmanların özellik haritaları, geçerli katmana girdi olarak birleştirilir; bunu bir toplu normalleştirme katmanı, bir ReLU etkinleştirme katmanı ve küçük filtre boyutuna sahip bir evrişim katmanı izler. Bu sıra, her yoğun blok içinde birçok kez tekrarlanır (Cinar et al., 2022).

Özellik haritalarının boyutsallığını azaltmak ve parametre sayısını kontrol etmek için yoğun bloklar arasına geçiş katmanları eklenir. Geçiş katmanı, toplu normalleştirme katmanı, 1x1 evrişim katmanı ve 2x2 ortalama havuzlama katmanından oluşur (Iandola et al, 2014).

Ağın sonuna, genel bir ortalama havuzlama katmanı eklenir ve ardından görüntüyü sınıflandırmak için softmax aktivasyonu ile tamamen bağlı bir katman gelir.

DenseNet'in geleneksel evrişimli sinir ağlarına göre çeşitli avantajları vardır. Yoğun bir şekilde bağlı katmanlar, daha verimli özellik yeniden kullanımına izin verir, bu da daha iyi parametre verimliliğine ve daha az fazla uydurmaya yol açar. DenseNet ayrıca, daha az parametre

kullanarak ve daha az hesaplama kaynağı gerektirerek, bir dizi görüntü tanıma görevinde en son teknoloji performansı elde eder.

DenseNet ayrıca, DenseNet-BC (darboğaz katmanlarına sahip DenseNet) ve DenseNet-SE (sıkıştır ve uyarma bloklarına sahip DenseNet) mimarileri gibi diğer mimarilerin geliştirilmesine de ilham vermiştir.

Genel olarak, DenseNet, bilgisayar görüşü alanına önemli katkılarda bulunan ve görüntü tanıma görevlerinde en son teknolojiyi geliştiren güçlü bir derin sinir ağı mimarisidir (Iandola et al., 2014).

3.9 Inception V3 Modeli

Inception V3, Google şirketi tarafından geliştirilmiştir. Derin öğrenme modelidir ve resim sınıflandırma ve nesne tespiti için kullanılır. Inception V3, Inception serisinin üçüncü versiyonudur ve önceki versiyonlara kıyasla daha yüksek doğruluk sağlamak için geliştirilmiştir.

Inception V3, çeşitli boyutlardaki filtrelerin ve pooling katmanlarının bir arada kullanımı ile oluşturulmuştur. Bu yaklaşım, ağı daha derin hale getirmeden daha fazla öğrenme kapasitesi sağlar. Ayrıca, modelde batch normalization ve ReLU gibi diğer yenilikler de bulunur.

Inception V3, imageNet veri kümesi üzerinde eğitilmiştir ve bu veri kümesinde 1000 farklı nesne sınıfını tanıyabilir. Inception v3, özellikle görsel işleme alanında birçok uygulama için başarılı sonuçlar vermiştir (Russakovsky et al., 2015).

Özellikle Inception v3, her biri 1x1, 3x3 ve 5x5 evrişimlerin yanı sıra havuzlama işlemlerinin bir kombinasyonunu içeren birden fazla yığılmış Inception modülünden oluşan gelişmiş bir mimariye sahiptir. Çeşitli çekirdek boyutlarının paralel olarak kullanılması, ağın farklı ölçeklerdeki özellikleri yakalamasına ve değişen karmaşıklıkta kalıpları tanımasına olanak tanır (Russakovsky et al., 2015).

Inception V3'te sunulan bazı önemli özellikler ve iyileştirmeler şunları içerir:

Faktörleştirilmiş evrişim: Hesaplama maliyetini azaltmak için çarpanlara ayrılmış evrişimler kullanılır. Büyük çekirdek boyutuna sahip tek bir evrişim yerine 1xN ve Nx1 evrişimlerinin bir

kombinasyonunu kullanır. Bu, mekânsal hiyerarşilerin daha verimli bir şekilde yakalanmasına yardımcı olur.

Yardımcı Sınıflandırıcılar: Inception v3, eğitim sırasında ara katmanlara yardımcı sınıflandırıcılar sunar. Bu yardımcı sınıflandırıcılar, eğitim sırasında daha kararlı ve daha hızlı yakınsamaya yardımcı olarak, yok olan gradyan sorununun azaltılmasına yardımcı olmak için ek denetim sinyalleri sağlar.


Toplu Normalleştirme: Toplu normalleştirme, her katmanın girişlerine uygulanır, eğitim sırasında daha hızlı yakınsamaya yardımcı olur ve bir dereceye kadar düzensizleştirme sağlar (Russakovsky et al, 2015).

Etiket Düzeltme: Etiket yumuşatma, eğitim etiketlerine uygulanan bir düzenleme tekniğidir. Temel doğruluk etiketlerine yumuşatılmış değerlerin ve diğer yanlış sınıflara kalan olasılık kütesinin atanmasını içerir. Bu, aşırı uyumun önlenmesine yardımcı olur ve genellemeyi geliştirebilir.

Küresel Ortalama Havuzlama: Inception V3, ağın sonunda tamamen bağlı katmanlar yerine küresel ortalama havuzlamayı kullanır. Bu, modeli basitleştirir ve mekânsal bilgiyi korurken parametre sayısını azaltır.

Inception v3, çeşitli görüntü sınıflandırma kriterlerinde son teknoloji performansı sergilemiştir ve derin öğrenme topluluğunda geniş çapta benimsenmiştir. Orijinal tasarımı daha da geliştiren ve geliştiren Inception v4 ve Inception-ResNet gibi Inception mimarisinin sonraki yinelemeleri için bir temel görevi görür (Liakos et al, 2018).

Inception v3, ayrıca transfer öğrenme için de kullanılabilir. Önceden eğitilmiş bir Inception v3 modeli, yeni bir veri kümesine adapte edilebilir veya bir başka görev için finetune edilebilir. Bu sayede, önceden eğitilmiş bir modelin öğrenilmiş özellikleri, başka bir problemin çözümünde kullanılabilir ve daha hızlı ve verimli bir öğrenme sağlanabilir. Şekil 3.19'da Inception v3 modelinin yapı şeması gösterilmiştir.



Şekil 3.19 Inception V3 modelinin yapı şeması (Cao et al., 2021).

Inception v3, özellikle nesne tespiti gibi zorlu görsel işleme problemleri için kullanışlıdır. Nesne tespiti, bir görüntüdeki nesnelerin konumunu ve boyutunu belirleme işlemidir. Inception v3, bu işlemde kullanılan birçok teknik, özellik ve algoritmayı içerir ve bu sayede nesne tespiti için yüksek doğruluk sağlayabilir.


Inception V3, günümüzde birçok uygulama alanında kullanılmaktadır. Örneğin, akıllı telefonların kameralarında kullanılan nesne tespiti ve otomatik odaklama, Inception V3 gibi derin öğrenme modelleri ile gerçekleştirilir. Ayrıca, çeviri, konuşma tanıma ve doğal dil işleme gibi diğer alanlarda da Inception V3 modeli transfer öğrenme için kullanılmaktadır (Liakos et al., 2018).

Inception V3 modeli, dikkate alınan karmaşık, yoğun mühendislik gerektiren bir ağıdır.

CNN, doğruluğu artırmanın tek yolunun katmanları katmanlar halinde istiflemek olduğunu iddia edilse de bu ağ, doğruluğu artırmak için bazı çözümler önermiş ve birçok katmanı yığmadan ana modeller oluşturur (Szegedy et al, 2015).

Inception V3 model yapısını eğitilebilir hale getirmek çok maliyetli ve zaman alıcı olduğundan, transfer öğrenme yöntemi kullanılmış ve modelin daha önceki özellikleri korunarak kullanılmıştır. Inception V3 modelinin son katmanının çıktı şekli alınarak yeni katmanlar ilave

edilmiştir. Inception V3 modelinin hemen sonrasında modeli daha kullanışlı ve düzenli hale getirmek için Batch Normalization katmanı ilave edilmiştir. Sonrasında modele eklenen evrişim katmanları ile minimum seviyede kayıp ile daha iyi sonuçlar elde etmek hedeflenmiştir (Mujahid et al., 2022). Şekil 3.20’de Inception V3 modelinin veri işleme şeması gösterilmiştir.



Şekil 3.20 Inception v3 modelinin veri işleme şeması.

Ayrıca başlangıçta kullanılan modüller daha küçük kıvrımları kullanması nedeniyle yeni ve oldukça kullanılan bir kavramdır. InceptionV3 modeli daha fazlasını derinlik toplama ve topladığı derinliği sayesinde hesaplama hızını etkilemeden bilgi Evrişim işlemlerinde kullanılan çeşitli çekirdek boyutlarına sahiptir (Mujahid et al., 2022).


3.10 Xception Modeli

Xception, (Extreme Inception) derin öğrenme modellerinde kullanılan bir evrişimsel sinir ağı mimarisi yöntemidir. İlk olarak François Chollet tarafından 2017 yılında bir makalede açıklanmış ve kullanılmıştır. Xception modeli, Google Inception mimarisini temel alarak

genişletilmiş ve daha iyi hale getirilerek kullanıma sunulmuş bir modeldir. Xception'un bazı temel özellikleri şunlardır;

Depthwise Separable Convolutions: Xception, klasik evrişim katmanlar kullanmaz. Bunun yerine depthwise separable convolution modeli kullanır. Bu yöntem, evrişim işlemini iki ayrı adımda ele alır bunlar; Depthwise Convolution ve Pointwise Convolution adımlarıdır.

Daha az parametreye ihtiyaç duyduğu için hesaplama maliyetlerini oldukça düşüren Xception modeli aynı zamanda daha fazla derinliğe sahip daha geniş ağlar oluşturmamıza da olanak tanır. Özellikle çözünürlüğü yüksek olan görüntülerin işlenmesinde yüksek performans sağlar. Görüntü sınıflandırmadan nesne algılamaya kadar pek çok alanda kullanılan Xception modeli segmentasyon ve transfer öğrenme alanlarında da oldukça etkili sonuçlar alınmasına olanak verir. Resim 3.21'de Xception modeline ait görüntü işleme metodu verilmiştir. (Chollet F.,2017).



Resim 3.21 Xception modeli (Opengenus Portalı, 2025).

Xception modeli, depthwise separable convolutions kullanarak klasik konvolüsyonlara kıyasla daha az parametreye ihtiyaç duyar. Diğer ağ yapılarına kolay bir şekilde bütünlüğüne edilebilir ve farklı veri kümelerinde adaptasyonu oldukça yüksektir. Görüntü sınıflandırmada ve özellik görüntü çıkarma görevlerinde state-of-the-art sonuçları sunarak kullanıcıya avantajlar sağlamaktadır. Dezavantajları ise modelin kullanım yapısı gereği küçük olan veri kümeleri ile çalışmada (overfitting) aşırı öğrenme sorununa neden olabilir. Ayrıca Xception

modeli genel olarak 299 x 299 boyutunda büyük veri girişlerine ihtiyaç duyar. Diğer modellerde bu veri girişleri daha küçük boyutlu kullanılabilir.

3.11 VGG Modeli

VGG (Visual Geometry Group), görüntü sınıflandırması amacıyla oluşturulmuş bir evrişimli sinir ağı (CNN) mimari çeşididir. Oxford Üniversitesi Görsel Geometri Ekibi tarafından 2014 yılında ilk olarak tanıtılmıştır. VGG mimarisi, basit kullanımı ve görüntü tanıma görevlerindeki etkili yaklaşımları nedeniyle görüntü işleme metotlarında popüler hale gelmiştir.

VGG ağı, küçük boyutlu 3x3 filtreli birden fazla evrişimli katmandan ve ardından maksimum havuz sistemi katmanlarından meydana gelir. VGG'nin en dikkat çeken yenilikçi yaklaşımı, ağı derinliğinin (katman sayısı) artırıldığı, tekdüze bir yapıdan meydana gelen derin bir mimari kullanmaktır. VGG konfigürasyonları genellikle 'A'dan 'E'ye kadar olan harflerle isimlendirilir, katmanlar açısından 'A' en küçüğü ve 'E' en büyüğüdür.

En yaygın kullanılan VGG mimarileri VGG16 ve VGG19'dur:

VGG16: 13 evrişimli katman ve 3 tam bağlantılı katman olmak üzere 16 katmandan oluşur.

VGG19: 16 evrişimli katman ve 3 tam bağlantılı katman dâhil olmak üzere 19 katmandan oluşan daha derin bir versiyondur.

VGG ağları, görüntü sınıflandırma, nesne algılama ve yerleştirme dâhil olmak üzere çeşitli bilgisayarlı görme görevlerinde rekabetçi sonuçlar elde etti. Ancak daha verimli ve ölçeklenebilir mimarilere olan talebin artması nedeniyle ResNet, Inception ve EfficientNet gibi daha yeni modeller son yıllarda popülerlik kazanmıştır (İnik, 2019).

VGG16, VGG (Görsel Geometri Grubu) sinir ağı mimarisine ait bir yöntem çeşididir. VGG16, görüntü sınıflandırma basit ve etkili kullanım tarzıyla dikkat çekmiştir. VGG16'daki "16" rakamı, ağıdaki toplam katman sayısını ifade eder (Yang, et al. 2021).


VGG16 mimarisinin bir özeti aşağıda sunulmuştur:

Giriş Katmanı: Giriş olarak bir RGB görüntüsünü alır.

Evrişim Blokları: 3x3 filtreli birkaç ardışık evrişim katmanından ve ardından bir maksimum düzeydeki havuzlama katmanından oluşur. Bu blok yapısı ağıın derinliğini arttırmak için birçok sefer tekrar edilerek kullanılır.

Tamamen Bağlantılı Katmanlar: Evrişim bloklarından sonra ağda üç adet tamamen bağlı katman bulunur.

Çıkış Katmanı: Tipik olarak, sınıflandırma görevleri için çıkış katmanında bir softmax aktivasyon fonksiyonu uygulanır. Çıkış katmanındaki düğüm sayısı, sınıflandırma problemindeki sınıf sayısına denk gelir. VGG16'nın detaylı mimarisi aşağıdaki gibidir:




Resim 3.22 VGG-16 modeli (Medium Portalı, 2025).

Küçük 3x3 filtrelerin kullanımı ve evrişimli blokların maksimum havuzlamayla tekrarlanması, VGG16'nın ayırt edici yapısına katkıda bulunur. VGG16 etkili olsa da ResNet ve EfficientNet gibi daha yeni mimariler, çeşitli bilgisayarlı görme görevlerinde hem doğruluk hem de verimlilik açısından onu geride bıraktı. Şekil 3.22 VGG 16 Mimari haritası gösterilmiştir.

3.12 EfficientNet Modeli

EfficientNet, Google şirketi tarafından geliştirilmiş olan ve daha az parametre kullanarak daha iyi performans veren görsel sınıflandırma görevleri için kullanılan bir derin öğrenme mimarisi türüdür. EfficientNet, sınır ağları tasarımı açısından verimlilik ve özellikle performans için optimize edilmiş bir model türüdür. Bu kullanılan mimari hem modellerin doğruluk değerini artırmak hem de işlemlerde doğacak maliyetleri minimize etmek için ölçeklendirme stratejilerini sistemli bir şekilde kullanır.

EfficientNet, model ölçeklendirme stratejisi olarak, genişlik (width), derinlik (depth) ve çözünürlük (resolution) kavramlarını aynı anda ölçeklendirerek yeni bir yöntem ortaya koyar. Bu yöntem, "compound scaling" adı verilen bir ölçek stratejisidir ve çalışma mantığı genişlik olarak ağ sistemindeki katmanların kanal sayılarını artırır. Derinlik olarak ise ağa katman ekleyerek daha derin hale getirmektedir. Bu boyutların optimizasyonu modelin dengelenmesini ve verimlilik oranını artırır. EfficientNet, sırasıyla daha küçük ve hafif modellerden oluşan B0 modeli ile başlayıp daha büyük veri kümeleriyle yüksek doğruluk gerektiren B7 ile devam eden modellerden oluşur. Neural Architecture Search (NAS) otomatik ağıyla optimize edilir. Mobil cihazlarda ise Inverted Bottleneck Convolution (MBConv) katmanları kullanır. Bu sayede sınırlı donanımlarda daha verimli çalışma sağlar. Resim 3.23'te EfficientNet Mimari haritası gösterilmiştir (Marques et al., 2020).



Resim 3.23 EfficientNet modeli (Wisdomml Portalı, 2025).

3.13 NasNet Modeli

NASNet (Sinir Mimarisi Arama Ağı), Google şirketi tarafından üretilen Sinir Mimarisi Arama (NAS) teknolojisi kullanılarak oluşturulmuş bir sinir ağı teknolojisidir. NAS, sinir ağı mimarisinin üreticiler tarafından manuel olarak oluşturulmak yerine makine öğrenimi kullanılarak otomatik olarak optimize edildiği bir tekniktir.


Temel Özellikleri: Otomatik mimari tasarımı; NASNet, katman sayısını, filtre boyutlarını veya diğer parametreleri manuel olarak seçmek yerine, görüntü sınıflandırma gibi belirli bir görev için en uygun mimariyi bulmak amacıyla arama algoritmalarını (genellikle takviyeli öğrenmeye veya evrimsel stratejilere dayalı) kullanır. Modüler Yaklaşım: NASNet mimarisi, hücre adı verilen tekrarlanan modüllerden oluşturulmuştur. Normal Hücre: Bir görüntünün mekânsal boyutlarını kaydetmek için tasarlanmış bir modüldür. İndirgeme Hücresi: Bir görüntünün uzaysal boyutlarını azaltan bir modül (genellikle daha yüksek seviyelerde özellik çıkarımı için kullanılır). Ölçeklenebilirlik: Keşfedilen hücreler, farklı boyutlarda ve karmaşıklıkta ağlar oluşturmak için kullanılabilir. Bu, modeli farklı bilgi işlem gücüne (örneğin, mobil cihazlar veya sunucular için) uygulamasına olanak tanır. Verimlilik: NASNet, ResNet veya Inception gibi geleneksel ağlara kıyasla daha düşük hesaplama maliyetiyle yüksek doğruluk oranlarına ulaşır. Bu, NASNet'i özellikle sınırlı kaynaklarla yüksek doğruluğun önemli olduğu uygulamalar için kullanışlı kılar (Falconi et al., 2019).

NASNet'in başlıca Faydaları şunlardır:

Otomasyon: Manuel mimari tasarım ihtiyacını ortadan kaldırır, Optimizasyon: Geleneksel olarak tasarlanmış ağlardan daha iyi performans gösteren mimarileri bulur, Çok yönlülük: Sınıflandırma, nesne algılama, bölümlendirme ve diğer bilgisayarlı görme görevleri için uygundur.

NASNet, sinir ağlarının tasarımının otomatikleştirilmesinin geliştirme sürecini nasıl büyük ölçüde basitleştirebileceğini ve modellerin kalitesini nasıl artırabileceğini gösteriyor. Ancak en uygun mimariyi bulmak önemli bilgi işlem kaynakları gerektirir ve bu da pratikte kullanımını sınırlar. Resim 3.24'te NASNet Mimari haritası gösterilmiştir.

Neural Architecture Search



Resim 3.24 NasNet modeli (Theaisummer Portalı, 2025).

3.14 AlexNet Modeli

AlexNet, bilgisayarlı görme alanında önemli ilerlemeler sergileyen ilk derin evrişimli sinir ağı modelidir. 2012 yılında Alexey Kryzhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından geliştirilmiş ve ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC-2012) birincilik kazanmıştır. Ayrıca önceki yaklaşımlara göre sınıflandırma hata oranını %10'a varan oranda azaltmıştır. Temel olarak 8 mimari katmandan oluşan AlexNet ilk 5 katmanında evrişimli olarak görüntü özelliklerini çıkarırken, son katmanda daha önce çıkarılmış özelliklere göre karar verme işlemini gerçekleştirir.

ReLU aktivasyonu: AlexNet, aktivasyon fonksiyonu olarak sigmoidal veya hiperbolik tanjant yerine Doğrultulmuş Doğrusal Birimleri (ReLU) kullanır. Bu, kaybolan gradyan problemini önler ve öğrenmeyi hızlandırır.

GPU Eğitimi: AlexNet, eğitimi hızlandırmak için Grafik İşleme Birimlerinin (GPU'lar) gücünden aktif olarak yararlanan ilk modellerden biriydi. Bu, büyük miktarda ImageNet verisi üzerinde eğitim yapılmasını mümkün kıldı.


Bırakma: Tamamen bağılı katmanlar, aşırı uyumu önlemek için bırakma tekniğini kullanır. Bırakma, eğitim sırasında bazı nöronları rastgele kapatır, bu da modelin genelleme yeteneğini geliştirir.

Maksimum Havuzlama: AlexNet, önemli özellikleri korurken mekânsal çözünürlüğü azaltmak ve parametre sayısını azaltmak için maksimum havuzlama katmanlarını kullanır.

Veri ve Normalleştirme: Eğitim verilerinin miktarını artırmak için rastgele kırpma ve görüntü çevirme gibi büyütme teknikleri kullanılır. Modelin yakınsamasını artıran yerel zıtlık normalleştirme (LRN) yöntemi de kullanılır.

AlexNet, derin evrişimli ağların sınıflandırma görevlerinde önemli iyileştirmeler elde edebildiğini kanıtlamış ve bu da derin öğrenmeye büyük ilgi duyulmasına yol açmıştır. Ayrıca Hata azaltma ve gelecekteki araştırmalara etkisi sayesinde daha verimli çalışma sağlar.

AlexNet, derin öğrenme tarihinde büyük veri, modern GPU'lar ve yeni mimarilerin kullanımının yapay zekâ alanını nasıl dönüştürülebileceğini gösteren bir dönüm noktası olmuştur. (Lu et al., 2019). Resim 3.25'te AlexNet Mimari haritası gösterilmiştir.



Resim 3.25 AlexNet modeli (Viso.ai Portalı, 2025).

4. PERFORMANS DEĞERLENDİRMESİ

Sınıflandırma sorunları için ihtiyaç duyulan yeni bir model oluşturma veya var olan modellerin kullanılması sonucunda o model ile başarı elde edilmesi doğru olan tahminleme adedine göre hesaplanmaktadır. Bu durum, modelin iyi olup olmadığını tahminlemekten çok, sınıflandırmanın doğru olup olmadığı kısmında etkili olmaktadır. Bundan dolayı, sınıflandırmanın tahminleri değerlendirmelerini ifade edebilmek için karışıklık matrisinden faydalanılır. Test verileri kullanılarak bir sınıflandırma modeli yardımıyla elde edilen tahmini sınıflar ve gerçek sınıflar hakkında bilgi içeren matris, karışıklık matrisidir (Agatonovic-Kustrin ve Beresford, 2000).

ROC (Receiver Operating Characteristic) eğrisi, herhangi bir sınıflandırma modelinin performans apısını değerlendirmek amacıyla kullanılan grafiksel bir metottur. Modelin doğru pozitif oranı (True Positive Rate, TPR - Recall) ile yanlış pozitif oranı (False Positive Rate, FPR) arasındaki ilişkiyi gösterir (Keçeoğlu et.al.,2016).

Aşağıda fındıkların sınıflandırılmasında kullanılan karışıklık matrisi gösterilmiştir. Karışıklık matrisinde dört parametre vardır. Bunlar tp: doğru pozitifler, fp: yanlış pozitifler, fn: yanlış negatifler, tn: doğru negatifler olarak adlandırılır. Pozitif sınıfa doğru şekilde sınıflandırılan örneklerle gerçek pozitifler denir. Negatif sınıfa doğru şekilde sınıflandırılan örneklerle gerçek negatifler denir. Yanlış olarak negatif olarak sınıflandırılan pozitif sınıf örneklerine yanlış negatif denir ve yanlış bir şekilde pozitif olarak sınıflandırılan negatif sınıf örneklerine yanlış pozitif denir (Agatonovic-Kustrin ve Beresford, 2000).

4.1 Hesaplama Formülleri

Doğruluk (accuracy) bir ölçüt terimidir ve bir modelin veya tahminin doğru olma oranını ifade eder. Özellikle makine öğrenimi ve istatistiksel analizde kullanılır. Doğruluk formülü aşağıda verilmiştir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Duyarlılık (sensitivity), tıp ve istatistik gibi alanlarda kullanılan bir terimdir ve bir testin veya modelin hastalığı doğru şekilde tespit etme yeteneğini ifade eder. Aşağıda duyarlılık hesaplama formülü verilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (2)$$

Özgüllük (specificity), tıp ve istatistik gibi alanlarda kullanılan bir terimdir ve bir testin veya modelin sağlıklı durumu doğru şekilde tespit etme yeteneğini ifade eder. Aşağıda özgüllük hesaplama formülü verilmiştir.

$$\text{Özgüllük} = \frac{DP}{DP+YN} \quad (3)$$

Kesinlik (precision), bir sınıflandırma modelinin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu ölçen bir ölçüttür. Aşağıda kesinlik hesaplama formülü verilmiştir.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4)$$

f1-score, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir ölçüttür. Precision (kesinlik) ve recall (duyarlılık) ölçümlerinin harmonik ortalamasını temsil eder. Aşağıda f1-score hesaplama formülü verilmiştir.

$$f1\text{-Score} = \frac{DP}{2DP+YN+YP} \quad (5)$$

Negatif tahmin edilebilir sonuç (NPV), tıp ve istatistikte kullanılan bir terimdir ve bir testin veya modelin negatif sonuç vermesi durumunda, gerçekte negatif olan sonuçların oranını ifade eder (Singh et al., 2022). Aşağıda gerçekte negatif olan sonuçların oranını hesaplama formülü verilmiştir.

$$\text{Negatif tahmin edilebilir sonuç Value} = \frac{DN}{DN+YN} \quad (6)$$

Yanlış doğru oranı, bir sınıflandırma modelinin özellikle negatif sınıftaki örnekleri yanlışlıkla pozitif olarak sınıflandırma sıklığını ifade eder. Aşağıda Negatif tahmin edilebilir sonuç hesaplama formülü verilmiştir.

$$\text{Yanlış doğru oranı} = \frac{YP}{DN+YP} \quad (7)$$

Yanlış keşfedilen sonuç (FDR), bir sınıflandırma modelinin pozitif olarak sınıflandırdığı örneklerin kaçının gerçekte negatif olduğunu ifade eder. Aşağıda yanlış keşfedilen sonuç hesaplama formülü verilmiştir.

$$\text{Yanlış keşfedilen sonuç} = \frac{YP}{DP+YP} \quad (8)$$

Yanlış negatif sonuç (FN rate), bir sınıflandırma modelinin özellikle pozitif sınıftaki örnekleri yanlışlıkla negatif olarak sınıflandırma sıklığını ifade eder (Singh et al., 2022). Aşağıda Yanlış negatif sonuç Rate hesaplama formülü verilmiştir.

$$\text{Yanlış negatif sonuç} = \frac{YN}{DP+YN} \quad (9)$$

5.DENEYSEL SONUÇLAR

Tez çalışmasının uygulama aşaması, Google Colab platformunda gerçekleştirilmiştir. Deneyler, NVIDIA T4 grafik işlemcisine (GPU) ve 16 GB RAM'e sahip bir çalışma ortamında, Python programlama dili kullanılarak yürütülmüştür.

Çalışmamızda görüntü sınıflandırma kapsamında yapılan çalışmalar ve bu çalışmalarda kullanılan performans değer verilerine yer verilmiştir. Bu bağlamda, çalışmamıza ait veri setindeki örnek verileri, kullanılan veri seti, sınıf adetleri, sınıflandırmada elde edilen başarı sayıları değerlendirilerek aşağıdaki Çizelge 5,1'de gösterilmiştir.

Önceden eğitilmiş CNN modellerinin performans karşılaştırması orijinal veri seti ve veri çoğaltma yapılmış verilerin kullanıldığı veri seti sıralı olarak çizelge 5.1'de verilmiştir.

Kullanılan Model	Doğruluk (Val-Accuracy)	Doğruluk (Training Validation)	Kesinlik (Precision)	Geri Çağırma (Recall)	f1 skoru
DenseNet121	%95.17	%96.81	0.93	0.95	0.95
Inception V3	%93.44	%96.91	0.93	0.94	0.93
Xception	%83.20	%77.61	0.83	0.80	0.81
NasNet	%80.07	%79.54	0.85	0.74	0.73
AlexNet	%79.73	%84.17	0.87	0.79	0.77
EfficeNet	%81.17	%80.17	0.80	0.75	0.74
VGG 16	%90.44	%78.57	0.84	0.77	0.75
VGG 19	%83.98	%84.94	0.89	0.81	0.81

Kullanılan Model	Doğruluk (Val-Accuracy)	Doğruluk (Training Validation)	Kesinlik (Precision)	Geri Çağırma (Recall)	f1 skoru
DenseNet121	%96.94	%97.5	0.98	0.98	0.97
InceptionV3	%96.14	%95.45	0.86	0.83	0.82
Xception	%79.73	%82.77	0.83	0.83	0.83
Nasnet	%80.74	%81.61	0.85	0.82	0.81
AlexNet	%86.92	%91.16	0.91	0.91	0.91
EfficientNet	%80.49	%78.66	0.83	0.79	0.78
VGG 16	%93.59	%92.95	0.93	0.93	0.93
VGG 19	%85.96	%82.95	0.86	0.89	0.82

Modellerin başarıları; veri setinin eğitim, test ve doğrulama olacak şekilde kısımlara ayrılması ve hangi miktarlarda içerisinde dataya sahip olacağı çalışmayı yapan araştırmacıya endekslidir. Bu çalışmada toplam 8 sınıf ve toplam 2590 fındık meyvesi görüntüsü bulunan veri seti ile çalışma yapılmıştır ve model eğitimlerini ona göre tamamlanmıştır. Daha farklı ve fazla sayılı veri setleri ve veri seti bölme yöntemleri de denenerek karşılaştırılmalı sonuçların arasına eklenebilir.

5.1 DenseNet121 Modeli

Orijinal veri seti, DenseNet121 modeline uyarlanmış ve bu model kullanılarak %95,17 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, DenseNet121 modelinin doğrulama sonuçları sunulmaktadır.

Çizelge 5.2 DenseNet 121 doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.95	0.88	0.91	64
Hanımeli	0.99	1.00	0.99	76
Foşa	0.91	0.93	0.92	76
Karafındık	1.00	0.95	0.98	84
Palaz	0.91	0.97	0.94	30
Sivri	0.92	1.00	0.96	78
Tombul	0.94	1.00	0.97	46
DağFındığı	0.98	0.89	0.93	64
Accuary			0.95	518
Macro Avg.	0.95	0.95	0.95	518
Weighted Avg.	0.95	0.95	0.95	518


Çizelge 5.2' de verilen sonuçlara göre;

Fındık türlerinin sınıflandırma performansı aşağıdaki gibi değerlendirilmiştir:

- Çakıldak: Precision 0,9375, Recall 0,9836, F1-Score 0,96
- Hanımeli: Precision 1,00, Recall 0,9875, F1-Score 0,9937
- Foşa: Precision 1,00, Recall 0,9625, F1-Score 0,9809
- Karafındık: Precision 0,9512, Recall 1,00, F1-Score 0,9750


- Palaz: Precision 0,7917, Recall 0,9048, F1-Score 0,8444
- Sivri: Precision 1,00, Recall 0,9306, F1-Score 0,9640
- Tombul: Precision 0,8889, Recall 1,00, F1-Score 0,9412
- Dağ Fındığı: Precision 1,00, Recall 0,8793, F1-Score 0,9358

Genel Sınıflandırma Performansı: DenseNet121 modeli kullanılarak test veri setindeki tüm çeşitlerin genel doğruluk oranı %96,81 olarak hesaplanmıştır.



Şekil 5.1 50 epoch DenseNet 121 doğrulama eğrileri grafiği


Resim 5.2’te fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında DenseNet121 modelinin eğitim ve doğrulama grafiği.



Şekil 5.2 50 epoch DenseNet 121 doğrulama kaybı eğrileri

Resim 5.4'te fındık çeşidi sınıflandırması için model eğitimi sırasında DenseNet121 modelinin eğitim ve doğrulama kaybı görülmektedir.


Resim 5.3 DenseNet121 modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal eksende yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Cakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Kara Fındık sınıfını, “4” Palaz sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.




Şekil 5.3 Confusion matrix kullanımı DenseNet121

5.2 Inception V3 Modeli


Orijinal veri seti, InceptionV3 modeline uyarlanmış ve bu model kullanılarak %93,44 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, InceptionV3 modelinin doğrulama sonuçları ve Inception V3 ait grafikler ve değer tabloları verilmiştir.



Şekil 5.4 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Inception v3 modelinin eğitim ve doğrulama grafiği.



Şekil 5.5’de fındık çeşidi sınıflandırması için model eğitimi sırasında Inception v3 modelinin eğitim ve doğrulama kaybı.



Şekil 5.6 Confusion matrix kullanımı Inception v3

Şekil 5.6 Inception v3 modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal ekseninde yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafındık sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.

Çizelge 5.3 Inception V3 doğrulama sonuçları


Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.87	0.86	0.87	64
Hanımeli	0.99	1.00	0.99	76
Foşa	0.87	0.86	0.86	64
Karafındık	0.97	0.90	0.94	84
Palaz	0.90	0.93	0.92	30
Sivri	0.93	0.99	0.96	78
Tombul	1.00	1.00	1.00	46
DağFındığı	0.94	0.95	0.95	64
Accuary			0.93	518
Macro Avg.	0.94	0.93	0.94	518
Weighted Avg.	0.94	0.94	0.94	518

Çizelge 5.3’ de verilen sonuçlara göre;


Çakıldak sınıfı için precision değeri 0,87, recall değeri 0,86, f1-score 0,87 olarak elde edilmiştir. Hanımeli sınıfı için precision değeri 0,99, recall değeri 1,00, f1-score 0,99 olarak elde edilmiştir. Foşa sınıfı için precision değeri 0,87, recall değeri 0,86, f1-score 0,86 olarak elde edilmiştir. Karafındık sınıfı için precision değeri 0,97, recall değeri 0,90, f1-score 0,94 olarak elde edilmiştir. Palaz sınıfı için precision değeri 0,90, recall değeri 0,93, f1-score 0,92 olarak elde edilmiştir. Sivri sınıfı için precision değeri 0,93, recall değeri 0,99, f1-score 0,96 olarak elde edilmiştir. Tombul sınıfı için precision değeri 1,00, recall değeri 1,00, f1-score 1,00 olarak elde edilmiştir. Dağ fındığı sınıfı için precision değeri 0,94, recall değeri 0,95, f1-score 0,95 olarak elde edilmiştir. Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı Inception v3 modeline göre %96.91 olarak hesaplanmıştır.

5.3 Xception Modeli


Orijinal veri seti, Xception modeline uyarlanmış ve bu model kullanılarak %83,20 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, Xception modelinin doğrulama sonuçları ve Xception ait grafikler ve değer tabloları verilmiştir.



Şekil 5.7 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Xception modelinin eğitim ve doğrulama grafiği.



Şekil 5.8’de fındık çeşidi sınıflandırması için model eğitimi sırasında Xception modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.9 Confusion matrix kullanımı Xception

Şekil 5.9 Xception modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal eksende yer alan sayılar doğru sınıflandırmaların sayısını gösterirken,

diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafındık sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.

Çizelge 5.4 Xception Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.82	0.78	0.80	64
Hanımeli	0.99	1.00	0.99	76
Foşa	0.88	0.79	0.83	76
Karafındık	0.81	0.80	0.80	84
Palaz	0.72	0.43	0.54	30
Sivri	0.82	0.94	0.87	78
Tombul	0.95	0.91	0.93	46
DağFındığı	0.64	0.78	0.70	64
Accuary			0.83	518
Macro Avg.	0.83	0.93	0.94	518
Weighted Avg.	0.84	0.83	0.83	518


Çizelge 5.4’ de verilen sonuçlara göre;

"Çakıldak" sınıfı için precision değeri 0,82, recall değeri 0.78, f1-score 0,80 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.99, recall değeri 1.00, f1-score 0,99 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.88, recall değeri 0.79, f1-score 0,83 olarak elde edilmiştir. "Karafındık" sınıfı için precision değeri 0.81, recall değeri 0.80, f1-score 0,80 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.72, recall değeri 0.43, f1-score 0,54 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.82, recall değeri 0.94, f1-score 0,87 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.95, recall değeri 0.91, f1-score 0,93 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0.64, recall değeri 0.78, f1-score 0,70 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı Xception modeline göre %77,61 olarak bulunmuştur.

5.4 EfficientNet Modeli


Orijinal veri seti, EfficientNet modeline uyarlanmış ve bu model kullanılarak %81,17 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, EfficientNet modelinin doğrulama sonuçları ve EfficientNet ait grafikler ve değer tabloları verilmiştir.



Şekil 5.10 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında EfficientNet modelinin eğitim ve doğrulama grafiği.



Şekil 5.11’de fındık çeşidi sınıflandırması için model eğitimi sırasında EfficientNet modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.12 Confusion matrix kullanımı EfficientNet

Şekil 5.12 EfficientNet modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal eksende yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Cakildak

sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafindik sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.

Çizelge 5.5 EfficientNet Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.88	0.70	0.78	64
Hanımeli	0.96	0.99	0.97	76
Foşa	0.86	0.80	0.83	76
Karafindik	0.83	0.80	0.81	84
Palaz	0.67	0.07	0.12	30
Sivri	0.70	0.92	0.80	78
Tombul	0.93	0.87	0.90	46
DağFındığı	0.60	0.83	0.70	64
Accuary			0.80	518
Macro Avg.	0.80	0.75	0.74	518
Weighted Avg.	0.81	0.80	0.79	518

Çizelge 5.5’ de verilen sonuçlara göre;


"Cakıldak" sınıfı için precision değeri 0,88, recall değeri 0.70, f1-score 0,78 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0,96, recall değeri 0,99, f1-score 0,97 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.86, recall değeri 0.80, f1-score 0,83 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 0.83, recall değeri 0.80, f1-score 0,81 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.67, recall değeri 0.07, f1-score 0,12 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.70, recall değeri 0.92, f1-score 0,87 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.95, recall değeri 0.91, f1-score 0,80 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0,60, recall değeri 0.83, f1-score 0,70 olarak elde edilmiştir.

Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı EfficeNet modeline göre %79,54 olarak bulunmuştur.

5.5 NasNet Modeli

Orijinal veri seti, NasNet modeline uyarlanmış ve bu model kullanılarak %80.07 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, NasNet modelinin doğrulama sonuçları ve NasNet ait grafikler ve değer tabloları verilmiştir.


Şekil 5.13 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında NasNet modelinin eğitim ve doğrulama grafiği.



Şekil 5.14'de fındık çeşidi sınıflandırması için model eğitimi sırasında NasNet modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.15’de fındık çeşidi sınıflandırması için model eğitimi sırasında NasNet modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.16 Confusion matrix kullanımı NasNet

Şekil 5.16 NasNet modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal ekseninde yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafindik sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ findığı sınıfını temsil etmektedir.

Çizelge 5.6 NasNet Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.95	0.66	0.78	64
Hanımeli	0.99	0.99	0.99	76
Foşa	0.77	0.86	0.81	76
Karafindik	0.91	0.75	0.82	84
Palaz	1.00	0.01	0.06	30
Sivri	0.64	0.96	0.77	78
Tombul	0.93	0.85	0.89	46
DağFındığı	0.61	0.81	0.70	64
Accuary			0.80	518
Macro Avg.	0.85	0.74	0.73	518
Weighted Avg.	0.84	0.80	0.78	518


Çizelge 5.6’ de verilen sonuçlara göre;

Çakıldak sınıfı için precision değeri 0,95, recall değeri 0,66 ve f1-score 0,78 olarak hesaplanmıştır. Hanımeli sınıfında precision 0,99, recall 0,99 ve f1-score 0,99 değerleri elde edilmiştir. Foşa sınıfı için precision 0,77, recall 0,86 ve f1-score 0,81 olarak bulunmuştur. Karafindik sınıfında precision değeri 0,91, recall değeri 0,75 ve f1-score 0,82 olarak tespit edilmiştir. Palaz sınıfı için precision 1,00, recall 0,07 ve f1-score 0,12 değerleri hesaplanmıştır. Sivri sınıfında ise precision değeri 0,70, recall değeri 0,03 ve f1-score 0,06 olarak elde edilmiştir. Tombul sınıfı için precision 0,93, recall 0,85 ve f1-score 0,89 olarak bulunmuştur. Dağ findığı sınıfında ise precision 0,61, recall 0,81 ve f1-score 0,70 değerlerine ulaşılmıştır.


Genel olarak, NasNet modeli kullanılarak test veri seti üzerindeki tüm sınıfların ortalama sınıflandırma doğruluk oranı%84,17 olarak hesaplanmıştır.

5.6 AlexNet Modeli


Orijinal veri seti, AlexNet modeline uyarlanmış ve bu model kullanılarak %79,73 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, AlexNet modelinin doğrulama sonuçları ve AlexNet ait grafikler ve değer tabloları verilmiştir.



Şekil 5.17 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında AlexNet modelinin eğitim ve doğrulama grafiği.



Şekil 5.18’de fındık çeşidi sınıflandırması için model eğitimi sırasında AlexNet modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.19 Confusion matrix kullanımı NasNet

Şekil 5.19 AlexNet modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal eksende yer alan sayılar doğru sınıflandırmaların sayısını

gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafındık sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ findığı sınıfını temsil etmektedir.

Çizelge 5.7 AlexNet Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.70	0.91	0.70	64
Hanımeli	0.96	1.00	0.98	76
Foşa	0.89	0.71	0.79	76
Karafındık	0.90	0.92	0.91	84
Palaz	1.00	0.03	0.06	30
Sivri	0.91	0.90	0.90	78
Tombul	0.93	0.93	0.93	46
DağFındığı	0.67	0.89	0.79	64
Accuary			0.84	518
Macro Avg.	0.87	0.79	0.77	518
Weighted Avg.	0.86	0.84	0.82	518


Çizelge 5.7’ de verilen sonuçlara göre;

"Çakıldak" sınıfı için precision değeri 0,70, recall değeri 0.91, f1-score 0,79 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.96, recall değeri 1.00, f1-score 0,98 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.89, recall değeri 0.71, f1-score 0,79 olarak elde edilmiştir. "Karafındık" sınıfı için precision değeri 0.90, recall değeri 0.92, f1-score 0,91 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 1.00, recall değeri 0.03, f1-score 0,06 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.91, recall değeri 0.90, f1-score 90 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.93, recall değeri 0.93, f1-score 0,93 olarak elde edilmiştir. "Dağ findığı" sınıfı için precision değeri 0.67, recall değeri 0.91, f1-score 0,77 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı AlexNet modeline göre %80,17 olarak bulunmuştur.

5.7 VGG16 Modeli


Orijinal veri seti, VGG16 modeline uyarlanmış ve bu model kullanılarak %90,44 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, VGG16 modelinin doğrulama sonuçları ve VGG16 ait grafikler ve değer tabloları verilmiştir.



Şekil 5.20 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında VGG 16 modelinin eğitim ve doğrulama grafiği.



Şekil 5.21’de fındık çeşidi sınıflandırması için model eğitimi sırasında VGG 16 modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.22 Confusion matrix kullanımı VGG 16

Şekil 5.22 VGG 16 modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal ekseninde yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Cakildak

sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafindik sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.

Çizelge 5.8 VGG 16 Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.98	0.66	0.79	64
Hanımeli	0.97	0.97	0.97	76
Foşa	0.78	0.88	0.83	76
Karafindik	1.00	0.36	0.53	84
Palaz	0.83	0.33	0.48	30
Sivri	0.96	0.96	0.96	78
Tombul	0.67	0.98	0.80	46
DağFındığı	0.51	1.00	0.67	64
Accuary			0.79	518
Macro Avg.	0.84	0.77	0.75	518
Weighted Avg.	0.86	0.79	0.77	518


Çizelge 5.8’ de verilen sonuçlara göre;

"Cakıldak" sınıfı için precision değeri 0,98, recall değeri 0.66, f1-score 0,79 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 0.97, f1-score 0,97 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.78, recall değeri 0.88, f1-score 0,83 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 1.00, recall değeri 0.36, f1-score 0,53 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.83, recall değeri 0.33, f1-score 0,48 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.96, recall değeri 0.96, f1-score 96 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.67, recall değeri 0.98, f1-score 0,80 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0.51, recall değeri 1.00, f1-score 0,67 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı VGG 16modeline göre %78,57 olarak bulunmuştur.

5.8 VGG19 Modeli


Orijinal veri seti, VGG19 modeline uyarlanmış ve bu model kullanılarak %83,98 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, VGG19 modelinin doğrulama sonuçları ve VGG19 ait grafikler ve değer tabloları verilmiştir.



Şekil 5.23 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında VGG 19 modelinin eğitim ve doğrulama grafiği.



Şekil 5.24’de fındık çeşidi sınıflandırması için model eğitimi sırasında VGG 19 modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.25 Confusion matrix kullanımı VGG 19

Şekil 5.25 VGG 19 modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal ekseninde yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafındık sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.

Çizelge 5.9 VGG 19 Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	F1-Score	Destek
Çakıldak	0.86	0.75	0.80	64
Hanımeli	1.00	1.00	1.00	76
Foşa	0.98	0.72	0.83	76
Karafındık	0.71	0.98	0.82	84
Palaz	1.00	0.23	0.38	30
Sivri	0.90	0.88	0.89	78
Tombul	0.94	0.98	0.96	46
DağFındığı	0.70	0.91	0.79	64
Accuary			0.85	518
Macro Avg.	0.89	0.81	0.81	518
Weighted Avg.	0.87	0.85	0.84	518

Çizelge 5.9’ de verilen sonuçlara göre;

"Çakıldak" sınıfı için precision değeri 0,98, recall değeri 0.66, f1-score 0,79 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 0.97, f1-score 0.97 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.78, recall değeri 0.88, f1-score 0,83 olarak elde edilmiştir. "Karafındık" sınıfı için precision değeri 1.00, recall değeri 0.36, f1-score 0,53 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.83, recall değeri 0.33, f1-score 0,48 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.96, recall değeri 0.96, f1-score 96 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.67, recall değeri 0.98, f1-score 0,80 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0.51, recall değeri 1.00, f1-score 0,67 olarak elde edilmiştir.

Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı VGG 19 modeline göre %84,94 olarak bulunmuştur.


5.9 Veri Artırma işlemi yapılmış veri seti

Orijinal veri seti, Colab ortamında Python programlama dili kullanılarak veri artırma yöntemleri ile genişletilmiştir. Veri artırma sürecinde sırasıyla döndürme (rotation), çevirme (flipping) ve ölçekleme (scaling) teknikleri uygulanmıştır. Veri artırımı sonucunda elde edilen genişletilmiş veri seti ile gerçekleştirilen analizlerin sonuçları aşağıda sunulmuştur. Çizelge 5.10 artırılmış sınıflandırmada elde edilen başarı sayıları.


Kullanılan Model	Doğruluk (Val-Accuracy)	Doğruluk (Training Validation)	Kesinlik (Precision)	Geri Çağırma (Recall)	f1 skoru
DenseNet121	%96,94	%97,5	0,98	0,98	0,97
InceptionV3	%96,14	%95,45	0,86	0.83	0.82
Xception	%79,73	%82,77	0.83	0.83	0.83
Nasnet	%80,74	%81,61	0.85	0.82	0.81
AlexNet	%86,92	%91,16	0.91	0.91	0.91
EfficientNet	%80,49	%78,66	0.83	0.79	0.78
VGG 16	%93,59	%92,95	0.93	0.93	0.93
VGG 19	%85,96	%82,95	0.86	0.89	0.82

5.9.1 DenseNet121 Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, DenseNet121 modeline uyarlanmış ve bu model kullanılarak %96,94 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, VGG16 modelinin doğrulama sonuçları ve DenseNet121 ait grafikler ve değer tabloları verilmiştir. Aşağıda DenseNet121 artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.26 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.27’de fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.28 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.28 DenseNet121 modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal eksende yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafindik sınıfını, “4” Palaz sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fıncığı sınıfını temsil etmektedir.

Çizelge 5.10 DenseNet121 Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.96	0.91	0.93	140
Hanımeli	1.00	1.00	1.00	140
Foşa	0.93	0.96	0.94	140
Karafindik	0.99	0.98	0.98	140
Palaz	0.97	0.98	0.98	140
Sivri	0.98	1.00	0.98	140
Tombul	0.99	1.00	1.00	140
Dağ fıncığı	0.64	0.78	0.70	140
Accuracy			0.97	1120
Macro Avg	0.98	0.98	0.97	1120
Weighted Avg	0.98	0.97	0.97	1120

Çizelge 5.10’ de verilen sonuçlara göre;


"Çakıldak" sınıfı için precision değeri 0,96, recall değeri 0.91, f1-score 0,83 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 1.00, recall değeri 1.00, f1-score 1.00 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.93, recall değeri 0.96, f1-score 0,94 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 0.99, recall değeri 0.98, f1-score 0,98 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.97, recall değeri 0.98, f1-score 0,98 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.98, recall değeri 1., f1-score 0.98 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.99, recall değeri 1.00, f1-score

1,00 olarak elde edilmiştir. “Dağ fındığı” sınıfı için precision değeri 0.64, recall değeri 0.78, f1-score 0,70 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı DenseNet121 modeline göre %97,5 olarak bulunmuştur

5.9.2 AlexNet Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, AlexNet modeline uyarlanmış ve bu model kullanılarak %86,92 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, AlexNet modelinin doğrulama sonuçları ve AlexNet ait grafikler ve değer tabloları verilmiştir. Aşağıda AlexNet artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.29 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.30'de fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.31 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.31 AlexNet modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal ekseninde yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Çakıldak sınıfını, “1” hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafindik sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ fındığı sınıfını temsil etmektedir.

Çizelge 5.12 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.89	0.96	0.92	140
Hanımeli	0.99	0.99	0.99	140
Foşa	0.98	0.96	0.91	140
Karafindik	0.97	0.91	0.94	140
Palaz	0.82	0.81	0.82	140
Sivri	0.90	0.99	0.94	140
Tombul	0.97	0.99	0.98	140
Dağ fındığı	0.79	0.80	0.79	140
Accuracy			0.91	1120
Macro Avg	0.91	0.91	0.91	1120
Weighted Avg	0.91	0.91	0.91	1120

Çizelge 5.9’ de verilen sonuçlara göre;


"Çakıldak" sınıfı için precision değeri 0,86, recall değeri 0.78, f1-score 0,82 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 1.00, f1-score 0,98 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.33, recall değeri 0.81, f1-score 0,82 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 0.87, recall değeri 0.89, f1-score 0,88 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.91, recall değeri 0.43, f1-score 0,58 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.86, recall değeri 0.85, f1-score 0,85 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.96, recall değeri 0.84, f1-score

0,90 olarak elde edilmiştir. “Dağ fındığı” sınıfı için precision değeri 0.54, recall değeri 0.93, f1-score 0,68 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı AlexNet modeline göre %91,16 olarak bulunmuştur.

5.9.3 NasNet Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, NasNet modeline uyarlanmış ve bu model kullanılarak %80,74 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, NasNet modelinin doğrulama sonuçları ve NasNet ait grafikler ve değer tabloları verilmiştir. Aşağıda NasNet artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.32 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.33’de fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.34 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.34 NasNet modelinin doğrulama seti için karışıklık matrisini göstermektedir. Karışıklık matrisinde, diyagonal eksende yer alan sayılar doğru sınıflandırmaların sayısını gösterirken, diğer sayılar yanlış sınıflandırmaların sayısını göstermektedir. “0” Cakildak sınıfını, “1”

hanımeli sınıfını, “2” Foşa sınıfını, “3” Karafindik sınıfını, “4” Palaza sınıfını, “5” Sivri sınıfını, “6” Tombul sınıfını ve “7” Dağ findığı sınıfını temsil etmektedir.

Çizelge 5.13 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakildak	0.86	0.78	0.82	140
Hanımeli	0.97	1.00	0.98	140
Foşa	0.83	0.81	0.82	140
Karafindik	0.87	0.89	0.88	140
Palaz	0.91	0.43	0.58	140
Sivri	0.86	0.85	0.85	140
Tombul	0.96	0.84	0.90	140
Dağ findığı	0.54	0.93	0.68	140
Accuracy			0.82	1120
Macro Avg	0.85	0.82	0.81	1120
Weighted Avg	0.85	0.82	0.81	1120


Çizelge 5.12’ de verilen sonuçlara göre;

"Çakildak" sınıfı için precision değeri 0,86, recall değeri 0.78, f1-score 0,82 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 1.00, f1-score 0,98 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.83, recall değeri 0.81, f1-score 0,82 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 0.87, recall değeri 0.89, f1-score 0,88 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.91, recall değeri 0.43, f1-score 0,58 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.86, recall değeri 0.85, f1-score 0,85 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.96, recall değeri 0.84, f1-score 0,90 olarak elde edilmiştir. "Dağ findığı" sınıfı için precision değeri 0.54, recall değeri 0.93, f1-score 0,68 olarak elde edilmiştir.

Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı NasNet modeline göre %81,61 olarak bulunmuştur

5.9.4 Xception


Veri artırımı uygulanmış veri seti, Xception modeline uyarlanmış ve bu model kullanılarak %79,73 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, Xception modelinin doğrulama sonuçları ve Xception ait grafikler ve değer tabloları verilmiştir. Aşağıda Xception artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.35 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.36’de fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.37 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.37, Xception modelinin artırılmış doğrulama seti üzerindeki karışıklık matrisini sunmaktadır. Karışıklık matrisinde, diyagonal eksenindeki değerler doğru sınıflandırma sayılarını ifade ederken, diğer hücrelerdeki değerler yanlış sınıflandırma sayılarını temsil etmektedir. Matris içerisinde sınıf etiketleri şu şekilde tanımlanmıştır: “0” Çakıldak, “1” Hanımeli, “2” Foşa, “3” Karafındık, “4” Palaz, “5” Sivri, “6” Tombul ve “7” Dağ Fındığı.

Çizelge 5.14 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.85	0.84	0.85	140
Hanımeli	0.97	1.00	0.98	140
Foşa	0.89	0.78	0.83	140
Karafındık	0.81	0.87	0.84	140
Palaz	0.72	0.62	0.67	140
Sivri	0.89	0.89	0.89	140
Tombul	0.90	0.90	0.90	140
Dağ fındığı	0.62	0.72	0.67	140
Accuracy			0.83	1120
Macro Avg	0.83	0.83	0.83	1120
Weighted Avg	0.83	0.83	0.83	1120

Çizelge 5.13’ de verilen sonuçlara göre;


"Çakıldak" sınıfı için precision değeri 0,85, recall değeri 0.84, f1-score 0,85 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 1.00, f1-score 0,98 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.89, recall değeri 0.78, f1-score 0,83 olarak elde edilmiştir. "Karafındık" sınıfı için precision değeri 0.81, recall değeri 0.87, f1-score 0,84 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.72, recall değeri 0.62, f1-score 0,67 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.89, recall değeri 0.89, f1-score 0,89 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.90,

recall değeri 0.90, f1-score 0,90 olarak elde edilmiştir. “Dağ fıncığı” sınıfı için precision değeri 0.62, recall değeri 0.72, f1-score 0,67 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı Xception modeline göre %82,77 olarak bulunmuştur.

5.9.5 InceptionV3 Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, InceptionV3 modeline uyarlanmış ve bu model kullanılarak %96,14 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, InceptionV3 modelinin doğrulama sonuçları ve InceptionV3 ait grafikler ve değer tabloları verilmiştir. Aşağıda InceptionV3 artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.38 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.39 fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.40 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.40, Inception V3 modelinin artırılmış doğrulama seti üzerindeki karışıklık matrisini sunmaktadır. Karışıklık matrisinde, diyagonal eksenindeki değerler doğru sınıflandırma sayılarını ifade ederken, diğer hücrelerdeki değerler yanlış sınıflandırma sayılarını temsil etmektedir.

Matris içerisinde sınıf etiketleri şu şekilde tanımlanmıştır: “0” Çakıldak, “1” Hanımeli, “2” Foşa, “3” Karafindik, “4” Palaz, “5” Sivri, “6” Tombul ve “7” Dağ Fındığı.

Çizelge 5.15 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.89	0.89	0.89	140
Hanımeli	0.98	1.00	0.99	140
Foşa	0.99	0.69	0.82	140
Karafindik	0.71	0.98	0.83	140
Palaz	0.92	0.39	0.55	140
Sivri	0.97	0.89	0.93	140
Tombul	0.81	0.97	0.88	140
Dağ fındığı	0.60	0.82	0.69	140
Accuracy			0.83	1120
Macro Avg	0.86	0.83	0.82	1120
Weighted Avg	0.86	0.83	0.82	1120


Çizelge 5.12’ de verilen sonuçlara göre;

"Çakıldak" sınıfı için precision değeri 0,85, recall değeri 0.84, f1-score 0,85 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 1.00, f1-score 0,98 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.89, recall değeri 0.78, f1-score 0,83 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 0.81, recall değeri 0.87, f1-score 0,84 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.72, recall değeri 0.62, f1-score 0,67 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.89, recall değeri 0.89, f1-score 0,89 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.90, recall değeri 0.90, f1-score 0,90 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0.62, recall değeri 0.72, f1-score 0,67 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı Inception V3 modeline göre %95,45 olarak bulunmuştur

5.9.6 EffcientNet Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, EffcientNet modeline uyarlanmış ve bu model kullanılarak %80,49 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, EffcientNet modelinin doğrulama sonuçları ve EffcientNet ait grafikler ve değer tabloları verilmiştir. Aşağıda EffcientNet artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.41 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.42 fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.43 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.43, EfficientNet modelinin artırılmış doğrulama seti üzerindeki karışıklık matrisini sunmaktadır. Karışıklık matrisinde, diyagonal eksenindeki değerler doğru sınıflandırma sayılarını ifade ederken, diğer hücrelerdeki değerler yanlış sınıflandırma sayılarını temsil etmektedir.

Matris içerisinde sınıf etiketleri şu şekilde tanımlanmıştır: “0” Çakıldak, “1” Hanımeli, “2” Foşa, “3” Karafindik, “4” Palaz, “5” Sivri, “6” Tombul ve “7” Dağ Fındığı.

Çizelge 5.16 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.93	0.62	0.74	140
Hanımeli	0.97	0.99	0.98	140
Foşa	0.76	0.86	0.81	140
Karafindik	0.87	0.85	0.86	140
Palaz	0.91	0.28	0.43	140
Sivri	0.76	0.90	0.83	140
Tombul	0.95	0.86	0.91	140
Dağ fındığı	0.51	0.92	0.66	140
Accuracy			0.79	1120
Macro Avg	0.83	0.79	0.78	1120
Weighted Avg	0.83	0.79	0.78	1120


Çizelge 5.15’ de verilen sonuçlara göre;

"Çakıldak" sınıfı için precision değeri 0,93, recall değeri 0.62, f1-score 0,74 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.97, recall değeri 0.99, f1-score 0,98 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.76, recall değeri 0.86, f1-score 0,81 olarak elde edilmiştir. "Karafindik" sınıfı için precision değeri 0.87, recall değeri 0.85, f1-score 0,86 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.91, recall değeri 0.28, f1-score 0,43 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.76, recall değeri 0.90, f1-score 0,83 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.50, recall değeri 0.86, f1-score 0,91 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0.51, recall değeri 0.92, f1-score 0,66 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı EfficeNet modeline göre %78,66 olarak bulunmuştur

5.9.7 VGG16 Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, VGG16 modeline uyarlanmış ve bu model kullanılarak %93,59 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, VGG16 modelinin doğrulama sonuçları ve VGG16 ait grafikler ve değer tabloları verilmiştir. Aşağıda VGG16 artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.44 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.45 fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.46 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.46, VGG 16 modelinin genişletilmiş doğrulama seti üzerindeki karışıklık matrisi sunulmaktadır. Bu matrisin diyagonal eksenindeki değerler doğru sınıflandırmaları ifade ederken, diğer hücrelerdeki değerler yanlış sınıflandırmaları göstermektedir. Matris içerisinde sınıf etiketleri şu şekilde tanımlanmıştır: “0” Çakıldak, “1” Hanımeli, “2” Foşa, “3” Karafındık, “4” Palaz, “5” Sivri, “6” Tombul ve “7” Dağ Fındığı.

Çizelge 5.17 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.91	0.96	0.93	140
Hanımeli	1.00	1.00	1.00	140
Foşa	0.98	0.91	0.94	140
Karafındık	0.93	0.99	0.96	140
Palaz	0.98	0.74	0.85	140
Sivri	0.98	0.94	0.86	140
Tombul	0.93	0.99	0.96	140
Dağ fındığı	0.78	0.90	0.83	140
Accuracy			0.93	1120
Macro Avg	0.93	0.93	0.93	1120
Weighted Avg	0.93	0.93	0.93	1120

Çizelge 5.16’ de verilen sonuçlara göre;


"Çakıldak" sınıfı için precision değeri 0,91, recall değeri 0.96, f1-score 0,83 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 1.00, recall değeri 1.00, f1-score 1,00 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.98, recall değeri 0.91, f1-score 0,94 olarak elde edilmiştir. "Karafındık" sınıfı için precision değeri 0.93, recall değeri 0.99, f1-score 0,96 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.98, recall değeri 0.74, f1-score 0,85 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.98, recall değeri 0.94, f1-score 0,96 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.93, recall değeri 0.99, f1-score

0,96 olarak elde edilmiştir. “Dağ fıncığı” sınıfı için precision değeri 0.78, recall değeri 0.90, f1-score 0,83 olarak elde edilmiştir.


Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı VGG 16 modeline göre %92,95 olarak bulunmuştur.

5.9.8 VGG19 Artırılmış Veri Seti Modeli


Veri artırımı uygulanmış veri seti, VGG19 modeline uyarlanmış ve bu model kullanılarak %85,96 doğruluk (Validation Accuracy) elde edilmiştir. Aşağıdaki tabloda, VGG19 modelinin doğrulama sonuçları ve VGG19 ait grafikler ve değer tabloları verilmiştir. Aşağıda VGG19 artırılmış veri seti modeline ait grafikler ve değer tabloları verilmiştir.



Şekil 5.47 fındık çeşitlerinin sınıflandırılması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama grafiği.



Şekil 5.48 fındık çeşidi sınıflandırması için model eğitimi sırasında Veri Artırma işlemi yapılmış veri seti modelinin eğitim ve doğrulama kaybı.



Şekil 5.49 Confusion matrix kullanımı Veri Artırma işlemi yapılmış veri seti.

Şekil 5.49, VGG 19 modelinin genişletilmiş doğrulama seti üzerindeki karışıklık matrisi sunulmaktadır. Bu matrisin diyagonal eksenindeki değerler doğru sınıflandırmaları ifade ederken, diğer hücrelerdeki değerler yanlış sınıflandırmaları göstermektedir. Matris içerisinde

sınıf etiketleri şu şekilde tanımlanmıştır: “0” Çakıldak, “1” Hanımeli, “2” Foşa, “3” Karafındık, “4” Palaz, “5” Sivri, “6” Tombul ve “7” Dağ Fındığı.

Çizelge 5.18 Veri Artırma işlemi yapılmış veri seti Doğrulama sonuçları.

Fındık Türü	Kesinlik	Geri Çağırma	f1-score	Destek
Çakıldak	0.89	0.89	0.89	140
Hanımeli	0.98	1.00	0.99	140
Foşa	0.99	0.69	0.82	140
Karafındık	0.71	0.98	0.83	140
Palaz	0.92	0.39	0.55	140
Sivri	0.97	0.89	0.93	140
Tombul	0.81	0.97	0.88	140
Dağ fındığı	0.60	0.82	0.69	140
Accuracy			0.83	1120
Macro Avg	0.86	0.83	0.82	1120
Weighted Avg	0.86	0.83	0.82	1120

Çizelge 5.16’ de verilen sonuçlara göre;

"Çakıldak" sınıfı için precision değeri 0,89, recall değeri 0.89, f1-score 0,89 olarak elde edilmiştir. "Hanımeli" sınıfı için precision değeri 0.98, recall değeri 1.00, f1-score 0,99 olarak elde edilmiştir. "Foşa" sınıfı için precision değeri 0.99, recall değeri 0.69, f1-score 0,82 olarak elde edilmiştir. "Karafındık" sınıfı için precision değeri 0.71, recall değeri 0.98, f1-score 0,83 olarak elde edilmiştir. "Palaz" sınıfı için precision değeri 0.92, recall değeri 0.39, f1-score 0,55 olarak elde edilmiştir. "Sivri" sınıfı için precision değeri 0.97, recall değeri 0.89, f1-score 0,93 olarak elde edilmiştir. "Tombul" sınıfı için precision değeri 0.81, recall değeri 0.97, f1-score 0,88 olarak elde edilmiştir. "Dağ fındığı" sınıfı için precision değeri 0.60, recall değeri 0.82, f1-score 0,69 olarak elde edilmiştir.

Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı VGG 19 modeline göre %82,95 olarak bulunmuştur



6. SONUÇLAR VE ÖNERİLER

Bu çalışma, sekiz farklı çeşit fındık görüntüsünü ile sınıflandırmayı amaçlamıştır.

Çalışmanın veri setinde fındık modellerine ait toplam 2590 adet görsel bulunmaktadır.

Palaz fındıktan 150 adet, dağ fındığından 320 adet, Foşa fındıktan 380 adet, tombul fındıktan 230 adet, hanımeli fındıktan 380 adet, çakıldak fındıktan 320 adet, kara fındıktan 420 adet ve sivri fındıktan 390 Adet görüntüyle çalışılmıştır. Bu görüntüler kendi kurduğumuz düzenek ile 10 cm mesafeden beyaz zeminde olacak şekilde elde edilmiş ve veri seti haline getirilmiştir.

Ön eğitilmiş (pre-trained) modeller, DenseNet121, Inception v3, NasNet, EfficeNet, AlexNet ve Xception ile fındık görüntüleri sınıflandırılmıştır. Veri kümeleri %20 test kümesi ve %80 eğitim kümesi olmak üzere bölümlere ayrılmıştır. Yapılan sınıflandırmalar sonucunda; sırasıyla %95,17, %93,44, %80,07, %81,17, %79,73 ve %83,20 sınıflandırma başarıları elde edilmiştir. Görüldüğü gibi en yüksek sınıflandırma başarıları DenseNet121 modeli ile elde edilmiştir. Çeşitli karışıklık matrisleri ve performans ölçümleri modellerin performanslarını daha detaylı analiz etmek için kullanılmıştır. Yine en yüksek değerler bu ölçümler modeli ile elde edilmiştir.

Veri artırımı teknikleri kullanılarak görüntüler çoğaltılmış ve yeniden değerlemeye alınmıştır. Yeniden değerlendirme işleminde kullanılan Ön eğitilmiş (pre-trained) modeller sırasıyla şunlardır; Densenet121, AlexNet, NasNet, Xception, Inception V3, VGG16, EfficeNet ve VGG-19. Bu derin öğrenme metotları eğitim başarı oranları sırasıyla şunlardır; %97,5, %91,16, %81,61, %82,77, %95,45, %92,95, %78,66, %82,95.

CNN mimarilerinde, katmanlar her zaman sınıflandırma başarıları ile doğru orantılı değildir. Yüksek sınıflandırma göre uygun değer sayıda katman içeren modeller ile başarı elde edilebilir. Çalışmada kullanılan yöntemler bu alanda ileride yapılacak çalışmalara örnek teşkil etmektedir. Çeşitli tarım ürünlerinin hasat sonrası sınıflandırılmasına yönelik birçok çalışma bulunmaktadır. Araştırmacılar tahribatsız sınıflandırma yapabilen prototipler geliştirmek için teknik ve yöntemlere odaklandılar. Bu yöntemler arasında yapay zekâ ve makine öğrenmesi güncel konular olarak öne çıkıyor. Bu yöntemler tarımsal ürünlerin sınıflandırılması ve otomasyonu için çözüm geliştirmede kullanılan konuların başında gelmektedir.

Diğer yandan, farklı sınıflandırma başarıları elde etmek mümkündür. Farklı yapay zekâ yöntemleri veri kümesindeki görüntü sayısına bağlı olarak, farklı modellerden farklı sınıflandırma başarıları elde edilebilir ve fındık çeşitleri hızlı ve etkili bir şekilde ayırt edilir. Farklı bir sınıflandırma çalışması yapılabilir. Farklı türde fındık görüntülerinin toplanması yapılabilir. Uygulama mobil yapılabilir ve tarım alanında fındığın cinsini belirlemek için kullanılır. Sınıflandırma sorunları için araştırmacılar tarafından gelecekteki çalışmalarda kullanılabilir.



KAYNAKLAR

- Agatonovic-Kustrin, S., ve Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717–727.
- Amaral, J. S., Casal, S., Citová, I., Santos, A., Seabra, R. M., ve Oliveira, B. P. P. (2006). Characterization of several hazelnut (*Corylus avellana* L.) cultivars based on chemical, fatty acid, and sterol composition. *European Food Research and Technology*, 222, 274–280.
- Ashtiani, S. H. M., Rohani, A., ve Aghkhani, M. H. (2020). Soft computing-based method for estimation of almond kernel mass from its shell features. *Scientia Horticulturae*, 262, 109071.
- Aydin, Sahin, and Dieaa Aldara. "Microservices-based databank for Turkish hazelnut cultivars using IoT and semantic web technologies." *Concurrency and Computation: Practice and Experience* 36.12 (2024): e8062.
- Balık, H. İ. (2021). Bioactive compounds and fatty acid composition of new Turkish hazelnut cultivars. *International Journal of Fruit Science*, 21(1), 106–114.
- Balık, H. İ., Kayalak Balık, S., ve Okay, A. (2015). Yeni fındık çeşitleri (Okay 28 ve Giresun Melezi). *Harran Tarım ve Gıda Bilimleri Dergisi*, 19(2), 104–109.
- Basha, C. Z., et al. (2020). Rainfall prediction using machine learning and deep learning techniques. In *2020 International Conference on Electronics and Sustainable Communication Systems (ICESC)* (pp. 1–6). IEEE.
- Bayrakdar, S., Çomak, B., Başol, D., ve Yücedağ, İ. (2015). Determination of type and quality of hazelnut using image processing techniques. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 616–619). Malatya, Turkey.
- Biçici, Y. (2023). Derin öğrenme ile mammogram görüntülerindeki lezyonların tespiti ve sınıflandırılması. Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü.
- Botta, R., Valentini, N., ve Me, G. (2019). Hazelnut (*Corylus spp.*) breeding. In *Advances in Plant Breeding Strategies: Nut and Beverage Crops*, 4, 157–219.
- Cao, J., Zhang, Y., ve Wang, Y. (2021). Application of a modified Inception-v3 model in the dynasty-based classification of ancient murals. *EURASIP Journal on Advances in Signal Processing*, 2021(1), 1–25.
- Chollet, François. "Xception: Deep learning with depthwise separable convolutions." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
- Çataloluk, H. (2012). Disease diagnosis using data mining methods on real medical data. Yüksek Lisans Tezi.

- Çetin, N., Sağlam, C., ve Türkmen, M. (2020). Determination of some physicochemical and biochemical parameters of hazelnut (*Corylus avellana L.*) cultivars. *Turkish Journal of Agriculture and Forestry*, 44(5), 439–450.
- El-Bendary, N., et al. (2015). Using machine learning techniques for evaluating tomato ripeness. *Expert Systems with Applications*, 42(4), 1892–1905.
- Erdoğan, V., Usta, C., Ayfer, M., ve Soylu, R. (2005). Incompatibility alleles expressed in pollen of Turkish hazelnut cultivars. *Turkish Journal of Biology*, 29(2), 111–116.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318.
- Erdoğan, V., Usta, C., Ayfer, M., ve Soylu, R. (2005). Incompatibility alleles expressed in pollen of Turkish hazelnut cultivars. *Turkish Journal of Biology*, 29(2), 111–116.
- Falconí, Lenin G., María Pérez, and Wilbert G. Aguilar. "Transfer learning in breast mammogram abnormalities classification with mobilenet and nasnet." *2019 international conference on systems, signals and image processing (IWSSIP)*. IEEE, 2019.
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318.
- Giraud, A., Calvini, R., Orlandi, G., Ulrici, A., Geobaldo, F., ve Savorani, F. (2018). Development of an automated method for the identification of defective hazelnuts based on RGB image analysis and colourgrams. *Food Control*, 94, 233–240.
- Guillén-Navarro, M. A., et al. (2020). A deep learning model to predict lower temperatures in agriculture. *Journal of Ambient Intelligence and Smart Environments*, 12(1), 21–34.
- Gupta, D., et al. (2022). Deep Learning for Medical Applications with Unique Data. *Academic Press*.
- Güneş, E. (2022). Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması (Master's thesis). *Marmara University, Turkey*.
- Güvenç, S. A., Şenel, F. A., ve Çetisli, B. (2015). Classification of processed hazelnuts with computer vision. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 1362–1365). Malatya, Turkey.
- Han, Y., et al. (2021). Quality estimation of nuts using deep learning classification of hyperspectral imagery. *Computers and Electronics in Agriculture*, 180, 105868.
- Hossain, M. S., Al-Hammadi, M., ve Muhammad, G. (2018). Automatic fruit classification using deep learning for industrial applications. *IEEE Transactions on Industrial Informatics*, 15(2), 1027–1034.

- Huang, G., Liu, Z., Van Der Maaten, L., ve Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 243–251).
- Huang, J., et al. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. In *Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 351–359).
- Iandola, F., Moskewicz, M. W., Karayev, S., ve Keutzer, K. (2014). DenseNet: Implementing efficient convnet descriptor pyramids. *arXiv preprint arXiv:1404.1869*.
- İnternet: Resarchgate URL-https://www.researchgate.net/publication/322397507_Hazelnut_Cultivars Son Erişim Tarihi 12.11.2024
- İnternet: Resarchgate URL-https://www.researchgate.net/publication/322397507_Hazelnut_Cultivars Son Erişim Tarihi 12.11.2024
- İnternet: Resarchgate URL-https://www.researchgate.net/publication/322397507_Hazelnut_Cultivars Son Erişim Tarihi 12.11.2024
- İnternet: Journals URL-<https://journals.tubitak.gov.tr/cgi/viewcontent.cgi?article=1083&context=agriculture> Son Erişim Tarihi 15.11.2024
- İnternet: E-arsiv URL-<http://earsiv.odu.edu.tr/xmlui/bitstream/handle/11489/1113/10241276.pdf?sequence=1&isAllowed=y> Son Erişim Tarihi 10.11.2024
- İnternet: Engati URL-<https://www.engati.com/glossary/data-augmentation> Son Erişim Tarihi 10.11.2024
- İnternet: Devnot URL-<https://devnot.com/2020/yapay-zeka-gelistirme-rehberi/> Son Erişim Tarihi 10.10.2024
- İnternet: Aoyilmaz URL-<https://aoyilmaz.medium.com/yapay-sinir-a%C4%9Flar%C4%B1-derindeki-g%C3%BCc%C3%BC-anlamak-54833ef3> Erişim Tarihi 01.10.2024
- İnternet: Hackernoon URL-<https://hackernoon.com/lang/tr/beyinden-ilham-alan-yapay-zeka-geli%C5%9Fimini-ara%C5%9F%C4%B1ran-bili%C5%9Fsel-paradigma> Son Erişim Tarihi 01.10.2024
- İnternet: Coderspace URL-<https://coderspace.io/blog/derin-ogrenme-nedir-deep-learning-nasil-calisir/> Son Erişim Tarihi 01.10.2024
- İnternet: Dergipark URL-<https://dergipark.org.tr/en/download/article-file/396994> Son Erişim Tarihi 01.12.2024
- İnternet: Researchgate URL-https://www.researchgate.net/figure/Machine-Learning-Vs-Deep-Learning_fig2_336348593 Son Erişim Tarihi 15.12.2024

- İnternet: Dergipark URL-<https://dergipark.org.tr/en/download/article-file/2482766> Son Erişim Tarihi 01.12.2024
- İnternet: Opendigen URL-<https://iq.opengenius.org/xception-model/> Son Erişim Tarihi 15.12.2024
- İnternet: Medium URL-<https://medium.com/@mygreatlearning/everything-you-need-to-know-about-vgg16-7315defb5918> Son Erişim Tarihi 15.12.2024
- İnternet: Wisdom URL-<https://wisdomml.in/efficientnet-and-its-performance-comparison-with-other-transfer-learning-networks/> Son Erişim Tarihi 15.10.2024
- İnternet: Theaisummer URL-<https://theaisummer.com/neural-architecture-search/> Son Erişim Tarihi 15.11.2024
- İnternet: Theaisummer URL-<https://viso.ai/deep-learning/alexnet/> Son Erişim Tarihi 15.12.2024
- Islam, A. (2003). Clonal selection in 'Uzunmusa' hazelnut. *Plant Breeding*, 122(4), 368–371.
- Islam, A. (2018). Hazelnut culture in Turkey. *Akademik Ziraat Dergisi*, 7(2), 259–266.
- Islam, A. (2019). Fındık ıslahında gelişmeler. *Akademik Ziraat Dergisi*, 8(Özel Sayı), 167–174.
- Islam, A., ve Ozgüven, A. I. (2001). Clonal selection in the Turkish hazelnut cultivars grown in Ordu Province. *Acta Horticulturae*, 556, 203–208.
- İnik, Ö. (2019). Derin öğrenme kullanarak ovaryum follikülerinin sınıflandırılması. *Yüksek Lisans Tezi*.
- Jiang, P., et al. (2020). Real-time fruit recognition and grasping estimation using deep learning in orchards. *Sensors*, 20(2), 509.
- Kalogirou, S., et al. (2016). Hazelnut harvesting and quality assessment in Greek cultivars. *Agricultural Engineering International: CIGR Journal*, 18(1), 178–188.
- Kaya, S., ve Koçyiğit, C. (2019). Determination of aflatoxin contamination levels in Turkish hazelnuts. *Journal of Food Safety*, 39(2), e12581.
- Keçeoğlu, Çiğdem, Selahattin Gelbal, and Nuri Doğan. "Roc eğrisi yöntemi ile kesme puanının belirlenmesi." *JASSS* 50.2 (2016): 553-562.
- Khan, M. A., et al. (2022). Intelligent agricultural systems for pest control and crop monitoring. *Expert Systems with Applications*, 205, 117763.
- Köksal, A. İ., ve Saydam, C. (2004). Physical properties of Turkish hazelnut varieties. *Journal of Food Engineering*, 65(2), 293–297.

- LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444.
- Li, H., et al. (2020). Application of convolutional neural networks in agricultural pest recognition: A review. *Computers and Electronics in Agriculture*, 178, 105736.
- Liu, J., ve Wang, X. (2021). Deep learning-based methods for pest detection in agriculture: A review. *Journal of Cleaner Production*, 312, 127903.
- Lu, Siyuan, Zhihai Lu, and Yu-Dong Zhang. "Pathological brain detection based on AlexNet and transfer learning." *Journal of computational science* 30 (2019): 41-47.
- Luo, J., et al. (2021). Smart agricultural monitoring using IoT-based platforms. *IEEE Internet of Things Journal*, 8(15), 11877–11889.
- Manolopoulou, H., et al. (2020). Modeling the drying kinetics of hazelnuts using machine learning techniques. *Journal of Food Engineering*, 275, 109871.
- Marques, Gonçalo, Deevyankar Agarwal, and Isabel De la Torre Díez. "Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network." *Applied soft computing* 96 (2020)
- Mehta, S., et al. (2018). ESPNet: Efficient spatial pyramid of dilated convolutions for semantic segmentation. *arXiv preprint*
- Mohanty, S. P., Hughes, D. P., ve Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, 1419.
- Pérez-Ruiz, M., et al. (2015). Advances in precision agriculture technologies for in-field monitoring and operations. *Precision Agriculture*, 16(4), 375–396.
- Rahnemoonfar, M., ve Sheppard, C. (2017). Deep count: Fruit counting based on deep simulated learning. *Sensors*, 17(4), 905.
- Rehman, A., et al. (2019). IoT-based smart agriculture: Toward making the fields talk. *IEEE Access*, 7, 129551–129583.
- 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, 91–99.
- Russakovsky, O., et al. (2015). ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211–252.
- Shah, D., et al. (2020). Plant disease detection using explainable AI. *Applied Soft Computing*, 98, 106837.
- Simonyan, K., ve Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

- Sun, Y., et al. (2021). Deep learning-based visual monitoring for agriculture: A review. *Information Processing in Agriculture*, 8(3), 327–342.
- Tang, Y., et al. (2017). Weed identification based on K-means feature learning combined with convolutional neural network. *Computers and Electronics in Agriculture*, 135, 63–70.
- Uijlings, J. R., et al. (2013). Selective search for object recognition. *International Journal of Computer Vision*, 104(2), 154–171.
- Wang, J., et al. (2020). A survey on deep learning for agriculture. *Computers and Electronics in Agriculture*, 175, 105438.
- Yang, G., et al. (2021). Smart agriculture powered by AI: Techniques, trends, and challenges. *IEEE Access*, 9, 362–385.
- Yang, Haoyan, et al. "A novel method for peanut variety identification and classification by Improved VGG16." *Scientific Reports* 11.1 (2021): 15756.
- Zhang, C., et al. (2018). Deep learning-based classification of multi-species pest images. *Journal of Integrative Agriculture*, 17(9), 1912–1922.

ÖZGEÇMİŞ

Adı-Soyadı : Selçuk HARMANCI

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

1-) S. Harmancı, Y. Ünal, B. Ateş, “Classification of Hazelnut Species with Pre-Trained Deep Learning Models”, Intell Methods Eng Sci, vol. 2, no. 2, pp. 58–66, Jun. 2023, doi: 10.58190/imiens.2023.14.

2-) B. Ateş, Y. Ünal, M. Kara, S. Harmancı, “Classification of Walnut Species with Pre-Trained Deep Learning Models” 9. Uluslararası 19 Mayıs Yenilikçi Bilimsel Yaklaşımlar Kongresi Samsun 2023.