

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ DOKTORA
PROGRAMI**

**KÖPEKLERİN UZUN KEMİKLERİNİN VE UZUN
KEMİKLERİNDEKİ
KIRIKLARIN SINIFLANDIRILMASI**

HAZIRLAYAN

GÜLNUR BEGÜM CANGÖZ

DOKTORA TEZİ

ANKARA – 2022

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ ANABİLİM DALI
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĐİ DOKTORA
PROGRAMI**

**KÖPEKLERİN UZUN KEMİKLERİNİN VE UZUN
KEMİKLERİNDEKİ
KIRIKLARIN SINIFLANDIRILMASI**

HAZIRLAYAN

GÜLNUR BEGÜM CANGÖZ

DOKTORA TEZİ

TEZ DANIŐMANI

DR. ÖĐR. ÜYESİ SELDA GÜNEY

ANKARA – 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Elektrik-Elektronik Mühendisliği Anabilim Dalı Doktora Programı çerçevesinde Gülnur Begüm CANGÖZ tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 14 / 02 / 2022

Tez Adı: Köpeklerin Uzun Kemiklerinin ve Uzun Kemiklerindeki Kırıkların Sınıflandırılması

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)	İmza
Prof. Dr. Hasan Şakir BİLGE (Gazi Üniversitesi)
Prof. Dr. Hasan OĞUL (Çankaya Üniversitesi)
Prof. Dr. Hamit ERDEM (Başkent Üniversitesi)
Dr. Öğr. Üyesi Emre SÜMER (Başkent Üniversitesi)
Dr. Öğr. Üyesi Selda GÜNEY (Başkent Üniversitesi)

ONAY

Prof. Dr. Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü
Tarih : ... / ... / 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 20 / 02 / 2022

Öğrencinin Adı, Soyadı: Gülnur Begüm CANGÖZ

Öğrencinin Numarası: 21810084

Anabilim Dalı: Elektrik-Elektronik Mühendisliği Anabilim Dalı

Programı: Elektrik-Elektronik Mühendisliği Doktora Programı

Danışmanın Unvanı/Adı, Soyadı: Dr. Öğretim Üyesi Selda GÜNEY

Tez Başlığı: Köpeklerin Uzun Kemiklerinin ve Uzun Kemiklerindeki Kırıkların Sınıflandırılması

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 89 sayfalık kısmına ilişkin, 20 / 02 / 2022 tarihinde şahsım/tez danışmanın tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 7'dir. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: 20 / 02 / 2022

Öğrenci Danışmanı Unvan, Adı, Soyadı, İmza:

Cangöz ailesine...

&

Tüm küçük masum canlara...

TEŐEKKÜR

Mutluluklarımda, üzüntülerimde, tecrübelerimde, başarılarımda ve daha nice yaşadıklarımda... Her gece Őükür dualarımda... Maddi ve manevi tüm değerlerimde, benliğimde, var olma sebebimde... Her Őeyde siz varsınız. Dünyaya bir kez daha gelsem, yine sizin evladınız olurdum.

Karanlık günlerime mumlar yakan can dostlarım... Yaktığınız her bir mum ile beni çıkıŐ noktasına getirdiniz. Őimdi daha aydınlık yolların yolcusuyuz. Hayat sizlerle güzel.

Yüksek lisans ile başlayıp doktora ile devam eden bu maceranın her anında yanımda olan, danışmanımdan öte artık ailemden biri olan canım hocam Selda Güney'e de en içten teşekkürü bir borç bilirim.

Varlığınız bana en güzel hediye.

ÖZET

Gülnur Begüm CANGÖZ

KÖPEKLERİN UZUN KEMİKLERİNİN VE UZUN KEMİKLERİNDEKİ KIRIKLARIN SINIFLANDIRILMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

2022

Son yılların en popüler konularından olan derin öğrenme algoritmaları, biyomedikal alanındaki problemlerin çözümünde önemli bir role sahiptir. Çeşitli görüntüleme yöntemleri ile elde edilen görüntüler kullanılarak hastalık ve kırık tespiti, biyolojik veri kestirimi, doku ve organ bölütlemesi, eksik veri tamamlanması gibi birçok uygulama bu algoritmalar sayesinde başarılı bir şekilde gerçekleştirilebilmektedir. Özellikle kemiklerdeki kırık tespiti, bu alanda en çok çalışılan konuların başında gelmektedir. Ancak bahsi geçen uygulamaların büyük bir çoğunluğu beşeri hekimlikte yer edinirken, veteriner tıpa hizmet eden uygulamalar daha geri planda bırakılmıştır. Özellikle literatürde bu alandaki eksikliğin fark edilmesi, tez konusunun en büyük motivasyon kaynağı olmuştur.

Bu tez çalışması kapsamında, Ankara Büyükşehir Belediyesi Sokak Hayvanları Geçici Bakım Evi'nden alınan, köpeklere ait X-ray görüntülerini içeren geniş kapsamlı bir veri seti meydana getirilmiştir. X-ray görüntülerinden uzun kemiğin çeşidinin belirlenmesi, kırığın varlığının saptanması ve var olması durumunda da kırığın cinsine göre sınıflandırılması hedeflenmiştir.

Sadece X-ray görüntülerine bakılarak kırık zamanının ve köpeğin yetişkinlik düzeyinin saptanabilmesi ise tez kapsamında yapılan diğer çalışmalar arasında yer almaktadır. Biyomedikal görüntü işleme alanındaki pek çok çalışma gibi, bu çalışmada da farklı derin öğrenme mimari karşılaştırılarak sonuçlar en iyileştirilmeye çalışılmıştır.

ANAHTAR KELİMELEER: Derin Öğrenme, Evrışimsel Sinir Ağları, Görüntü İşleme, Kırık Tespiti, Kırık Zamanı, Kırık Sınıflandırması, Köpek Yetişkinlik Düzeyi.

ABSTRACT

Gülnur Begüm CANGÖZ

CLASSIFICATION OF THE LONG BONES AND FRACTURES OF DOGS

Başkent University Institute of Science and Engineering

Department of Electrical and Electronics Engineering

2022

One of the most popular topics of recent years, deep learning algorithms find wide application in the biomedical field. Disease and fracture detection, biological data estimation, tissue and organ segmentation, missing data completion, and many more applications can be successfully performed using images obtained by various imaging methods, thanks to deep learning algorithms. In particular, fracture detection is one of the most popular subjects in this field. Nevertheless, most of these applications are made for human medicine. Therefore, veterinary medicine have been ignored drastically. The realization of the deficiency in this area has been the biggest motivation for the thesis.

In the thesis, a comprehensive data set containing X-ray images of dogs gathered from Ankara Metropolitan Municipality Stray Animals Temporary Care Home is created. It is aimed to determine the type of long bone from the images, then detect the presence of the fracture and, if present, classify the fracture type.

According to X-ray images, the determination of the fracture time and the maturity of the dog are other studies carried out within the scope of the thesis. Like many studies in the field of the biomedical image processing, different deep learning architectures are compared, and the results are tried to be optimized.

KEYWORDS: Convolutional Neural Networks, Deep Learning, Dog Maturity, Fracture Detection, Fracture Time, Fracture Classification, Image Processing.

ÖNSÖZ

Bu tez çalışmasında; Türkiye’de özellikle veteriner tıp alanındaki gereksinimlerin incelenmesi sonucu, veteriner hekimlerin ortopedi operasyonlarında yardımcı olabileceğine inanılan detaylı bir çalışmanın uygulanabilirliği incelenmek istenmiştir.

Bu kapsamda ihtiyaç duyulan veri setini paylaşarak, ilgili akademik çalışmaların önünü açan Ankara Büyükşehir Belediyesi Sokak Hayvanları Geçici Bakım Evi çalışanlarının büyük emeği vardır. Emekleri, tezin geliştirilmesi sürecine çok büyük katkı sağlamıştır.

Ankara Büyükşehir Belediyesi Sağlık İşleri Daire Başkanlığı’ndan veri setinin kullanım ve paylaşımına yönelik gerekli yasal izinler alınmıştır.



İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iii
ÖNSÖZ.....	iv
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	x
SİMGELER VE KISALTMALAR LİSTESİ	xiv
1. GİRİŞ	1
1.1. Tezin Amacı, Kapsamı ve Özgünlüğü.....	1
1.2. Problem Tanımı ve Motivasyon	4
1.2.1. Transversal kırıklar.....	6
1.2.2. Oblik (diyagonal) kırıklar	6
1.2.3. Çok parçalı kırıklar	7
1.3. Literatür Taraması.....	8
2. MATERYAL VE METOT.....	12
2.1. Veri Seti	12
2.2. Kullanılan Görüntü Ön İşleme Yöntemleri	14
2.3. Veri Çoğaltma Yöntemleri.....	16
2.3.1. Çevirme (flipping).....	18
2.3.2. Rotasyon (rotation)	18
2.3.3. Parlaklık (brightness)	18
2.3.4. Zıtlık (kontrast) değişimi.....	19
2.3.5. Bulanıklaştırma (Blurring)	19
2.4. Derin Öğrenme	21
2.4.1. Sıfırdan Öğrenme (Learn from Scratch).....	32
2.4.2. Öğrenme Aktarımı (Transfer Learning)	32
2.4.3. Tümevarımsal Öğrenme Aktarımı (Inductive Transfer Learning).....	34
2.4.4. Dönüştürücü Öğrenme Aktarımı (Transductive Transfer Learning).....	35
2.4.5. Gözetimsiz Öğrenme Aktarımı (Unsupervised Transfer Learning).....	35
2.4.6. Örnek Aktarımı (Instance Transfer)	35
2.4.7. Öznitelik Temsili Aktarımı (Feature Representation Transfer).....	35
2.4.8. Parametre Aktarımı (Parameter Transfer)	36

2.4.9.	İlişki Kurma Tecrübesi Aktarımı (Relational Knowledge Transfer)	36
2.5.	Derin Öğrenme Modelleri.....	36
2.5.1.	AlexNet.....	36
2.5.2.	GoogLeNet (Inception-v1)	36
2.5.3.	ResNet	37
2.5.4.	VGGNet	38
2.5.5.	DenseNet-201.....	39
2.5.6.	InceptionResNet-v2 (Inception-v2)	40
2.5.7.	Inception-v3.....	41
2.5.8.	Xception	41
2.6.	Destek Vektör Makineleri (Support Vector Machines, SVM)	42
2.7.	k-En Yakın Komşu Algoritması (k-Nearest Neighbours, k-NN)	45
2.8.	Kolektif Öğrenme (Ensemble Learning)	46
2.8.1.	Torbalama (Bootstrap Aggregation, Bagging) Tekniği	46
2.8.2.	Yükseltme (Boosting) Tekniği	46
2.9.	Naive Bayes Sınıflandırıcısı	47
2.10.	Sınıflandırma Performansını Ölçmede Kullanılan Teknikler.....	48
3.	TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR	50
3.1.	Köpeklerdeki Uzun Kemiklerin Sınıflandırılması.....	50
3.2.	X-ray Görüntülerinden Köpeklerin Yetişkinlik Düzeyinin Belirlenmesi	56
3.3.	X-ray Görüntülerinden Uzun Kemik Kırıklarının Zamana Göre Sınıflandırılması	62
3.4.	Köpeklerdeki Uzun Kemik Kırıklarının Belirlenmesi	66
3.4.1.	Farklı veri çoğaltma yöntemlerinin kırık tespiti üzerindeki etkisinin incelenmesi.....	68
3.5.	Köpeklerdeki Uzun Kemik Kırıklarının Sınıflandırılması.....	69
3.5.1.	Köpeklerdeki Uzun Kemik Kırıklarının Sınıflandırılmasında Başarı Artırımına Yönelik Yapılan İncelemeler	71
3.6.	Köpeklerdeki Uzun Kemiklere Göre Kırık Tespitinin Yapılması	74
3.7.	Köpeklerin Uzun Kemiklerinin ve Kırıklarının Sınıflandırılması.....	75
3.7.1.	Köpeklerin Uzun Kemiklerinin ve Kırıklarının Sınıflandırma Başarısını Artırmaya Yönelik Yapılan Çalışmalar	80
4.	TARTIŞMA VE YORUM.....	85
5.	SONUÇ.....	88

KAYNAKLAR.....	90
EKLER.....	101
EK 1: Veri Seti Kullanımı ve Paylaşımı için İzin Belgesi	101



TABLolar LİSTESİ

	Sayfa
Tablo 3.1. Veri setindeki görüntü sayıları.....	51
Tablo 3.2. Sınıflandırıcı çeşidine göre sınıflandırma başarıları	52
Tablo 3.3. Sınıflandırıcı çeşidine göre oluşturulan karmaşıklık matrisleri	53
Tablo 3.4. Ağ mimarilerine göre sınıflandırma başarıları.....	54
Tablo 3.5. Ağ mimarilerine göre oluşturulan karmaşıklık matrisleri.....	55
Tablo 3.6. Ağ mimarilerine göre sınıflandırma başarıları.....	59
Tablo 3.7. Çoğaltılmış veri kümesi ile ağ mimarilerine göre sınıflandırma başarıları	59
Tablo 3.8. Ham ve çoğaltılmış veri kümeleri ile ağ mimarilerine göre oluşturulan karmaşıklık matrisleri.....	61
Tablo 3.9. Ağ mimarilerine göre sınıflandırma başarıları.....	64
Tablo 3.10. Çoğaltılmış veri kümesi ile ağ mimarilerine göre sınıflandırma başarıları	64
Tablo 3.11. Ham ve çoğaltılmış veri kümeleri ile ağ mimarilerine göre oluşturulan karmaşıklık matrisleri.....	65
Tablo 3.12. Ağ mimarilerine göre sınıflandırma başarıları.....	66
Tablo 3.13. Çoğaltılmış veri kümesi ile ağ mimarilerine göre sınıflandırma başarıları	66
Tablo 3.14. Ham ve çoğaltılmış veri kümeleri ile ağ mimarilerine göre oluşturulan karmaşıklık matrisleri.....	67
Tablo 3.15. Veri çoğaltma yöntemlerine göre sınıflandırma başarıları	69
Tablo 3.16. Alt çalışmada kullanılan veri seti.....	70
Tablo 3.17. Ağ mimarilerine göre sınıflandırma başarıları.....	70
Tablo 3.18. Görüntü çoğaltması sonucu alt çalışmada kullanılan veri seti.....	73
Tablo 3.19. Çalışmada kullanılan görüntü sayıları.....	74
Tablo 3.20. Ağ mimarilerine göre sınıflandırma başarıları.....	75
Tablo 3.21. Kemik ve kırık çeşitlerine göre toplam görüntü sayıları.....	79

Tablo 3.22. Ağ mimarilerine göre sınıflandırma başarıları.....	79
Tablo 3.23. Çoğaltılmış veri seri ile 16 sınıf için yapılan sınıflandırmadaki başarı oranları... 80	
Tablo 3.24. Inception-v3 mimarisinden elde edilen karmaşıklık matrisi.....	82
Tablo 3.25. İlk kat için oluşturulan karmaşıklık matrisi	84



ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Yazılım iskeleti: 1. ve 2. görevler.	3
Şekil 1.2. Yazılım iskeleti: 3. ve 4. görevler.	3
Şekil 1.3. Yazılım iskeleti: 5. ve 6. görevler.	4
Şekil 1.4. Yazılım iskeleti: Temel görev.	4
Şekil 1.5. Transversal kırık [19].	6
Şekil 1.6. Oblik kırık [19].	7
Şekil 1.7. Çok parçalı kırıklar [19].	7
Şekil 2.1. Ecoray ultra HF100 veteriner röntgen cihazı.	12
Şekil 2.2. Fujifilm FCR PRIMA T2 görüntüleme cihazı.	13
Şekil 2.3. Canine (köpek) iskelet sistemi [38].	15
Şekil 2.4. Veri setinde kemik çeşidine göre etiketlenen sağlam görüntüler. a) femur, b) humerus, c) radius-ulna ve d) tibia.	15
Şekil 2.5. Veri setinde humerus kemiğine ait kırık çeşitlerine göre etiketlenmiş örnek görüntüler. a) transversal, b) oblik ve c) çok parçalı kırık.	16
Şekil 2.6. Sağlam femur kemiğine ait farklı boyut, parlaklık ve çekim açısındaki örnek görüntüler.	16
Şekil 2.7. Parlaklık değişimi sonucu veri setinden elde edilen görüntülere örnekler a) orijinal görüntü, b) orijinal görüntü matrisine 50 değerinin eklenmesiyle oluşan çıktı, c) orijinal görüntü matrisinden 50 değerinin çıkarılmasıyla oluşan çıktı.	18
Şekil 2.8. Veri çoğaltma işlemi sonucu elde edilen çıktı görüntülerine örnekler [48]. a) orijinal, b) çevirme, c) rotasyon, d) parlaklık değişimi, e) bulanıklaştırma.	20
Şekil 2.9. Veri çoğaltma işlemi sonucu veri setindeki bir görüntüden elde edilen çıktılara örnekler. a) orijinal, b) çevirme, c) rotasyon, d) parlaklık değişimi, e) bulanıklaştırma, f) kontrast değişimi.	20
Şekil 2.10. Klasik bir derin öğrenme modeli katmanları [56].	21
Şekil 2.11. LeNet mimarisi [57].	22
Şekil 2.12. Evrişim işlemi.	23

Şekil 2.13. Evrişim işlemi devamı.	24
Şekil 2.14. Evrişim işlemi sonucu.	24
Şekil 2.15. Dolgulama ile evrişim işlemi.	25
Şekil 2.16. Geri yayılım algoritması adımları.	26
Şekil 2.17. Havuzlama işlemi.	27
Şekil 2.18. Havuzlama işlemi devamı.	28
Şekil 2.19. Havuzlama işlemi sonucu.	28
Şekil 2.20. Sinir ağlarında kullanılan aktivasyon fonksiyonları ve türevleri. a) basamak fonksiyonu, b) doğrusal fonksiyon, c) sigmoid fonksiyonu, d) tanh fonksiyonu, e) ReLU fonksiyonu ve f) sızıntı ReLU fonksiyonu [60].	30
Şekil 2.21. Tam bağlaşımlı katman.	31
Şekil 2.22. Seyreltme (bırakma) işlemi.	32
Şekil 2.23. Sıfırdan öğrenme.	33
Şekil 2.24. Öğrenme aktarımı (sınıflandırma işlemi tam bağlaşımlı katman ile yapılmıştır). .	33
Şekil 2.25. Öğrenme akıllarımı (sınıflandırma işlemi destek vektör makineleri ile yapılmıştır).	34
Şekil 2.26. AlexNet mimarisi [63].	36
Şekil 2.27. GoogLeNet mimarisi [64].	37
Şekil 2.28. ResNet mimarisindeki artık blok yapısı.	38
Şekil 2.29. a) VGG-16 mimarisi , b) VGG-19 mimarisi [67].	39
Şekil 2.30. DenseNet mimarisindeki kısa yol bağlantıları [69].	40
Şekil 2.31. DenseNet mimarisi [68].	40
Şekil 2.32. InceptionResNet-v2 (Inception-v2) mimarisi [67].	41
Şekil 2.33. Inception-v3 mimarisi [67].	41
Şekil 2.34. Xception mimarisi [73].	42
Şekil 2.35. SVM sınıflandırıcının çalışma prensibini anlatan bir görsel [75].	44
Şekil 2.36. Karmaşıklık matrisi.	48

Şekil 3.1. Köpeklerde uzun kemikler [87].	51
Şekil 3.2. Veri setinde yer alan uzun kemik çeşitlerine birer örnek a) femur, b) humerus, c) radius-ulna ve d) tibia.	51
Şekil 3.3. Yaşlarına göre köpek radyografileri. a) 2 haftalık köpek yavrusu, b) 7 haftalık köpek yavrusu ve c) 1 yaşındaki yetişkin köpek [94].	57
Şekil 3.4. Yavru ve yetişkin köpeklere ait büyüme plakaları. a) yetişkin (büyüme plakası kapalı), b) yavru (büyüme plakası hala açık) [95].	57
Şekil 3.5. Oluşturulan veri setinden örnek genç ve yetişkin köpek görüntüleri. a) genç köpek ve b) yetişkin köpek.	58
Şekil 3.6. Bir kemiğin iyileşme süreci [105].	63
Şekil 3.7. Röntgen görüntülerinden bir kemiğin iyileşme süreci. a) yeni oluşan kırık, b) doku iyileşmesinin başlangıç aşaması, c) daha büyük kallus oluşumu. [106].	63
Şekil 3.8. Çoğaltma işleminden sonra veri setinden örnek görüntüler. a) dikey çevirme işlemi sonrası, b) 30 derece sola döndürülme sonrası, c) kontrast değişimi sonrası.	68
Şekil 3.9. Veri setinde yer alan kırık çeşitlerine birer örnek. a) oblik, b) parçalı, c) transversal ve d) sağlam.	70
Şekil 3.10. Kümeleme yapılarak bölütlenen veri setine ait örnek bir görüntü.	71
Şekil 3.11. Farklı kenar algılama metotları kullanılarak alınan çıktılara örnekler. a) orijinal, b) sobel, c) canny ve d) prewitt.	72
Şekil 3.12. Sobel metodu ile gri dönüşümü yapılmış orijinal görüntü matrislerinin toplamına ait örnek çıktı.	72
Şekil 3.13. Çoğaltma işlemi sonucu örnek görüntüler. a) orijinal, b) parlaklık değişimi: I-50, c) parlaklık değişimi: I+50, d) sigma=1 iken elde edilen bulanık görüntü. (I: orijinal görüntü matrisi)	73
Şekil 3.14. Çalışmayı özetleyen akış diyagramı.	77
Şekil 3.15. Femur kemiğine ait alt sınıflar. a) oblik kırığa sahip femur kemiği, b) çok parçalı kırığa sahip femur kemiği, c) sağlam femur kemiği, d) transversal kırığa sahip femur kemiği.	77
Şekil 3.16. Humerus kemiğine ait alt sınıflar. a) oblik kırığa sahip humerus kemiği, b) çok parçalı kırığa sahip humerus kemiği, c) transversal kırığa sahip humerus kemiği, d) sağlam humerus kemiği.	78
Şekil 3.17. Radius-ulna kemiğine ait alt sınıflar. a) oblik kırığa sahip radius-ulna kemiği, b) çok parçalı kırığa sahip radius-ulna kemiği, c) sağlam radius-ulna kemiği, d) transversal kırığa sahip radius-ulna kemiği.	78

Şekil 3.18. Tibia kemiğine ait alt sınıflar. a) oblik kırığa sahip tibia kemiği, b) çok parçalı kırığa sahip tibia kemiği, c) sağlam tibia kemiği, d) transversal kırığa sahip tibia kemiği.
..... 79



SİMGELER VE KISALTMALAR LİSTESİ

AC-GAN	Auxiliary Classifier- Generative Adversarial Network
BCS	Body Condition Score
CNN	Convolutional Neural Network
CT	Computed Tomography
FN	False Negative
FP	False Positive
GAN	Generative Adversarial Network
k-NN	k-Nearest Neighbour
MR	Manyetik Rezonans
PCA	Principal Component Analysis
PLS-DA	Partial Least Squares Discriminant Analysis
R-CNN	Region Based Convolutional Neural Network
ReLU	Rectifier Linear Unit
SSD	Single Shot Detector
SVM	Support Vector Machine
TN	True Negative
TP	True Positive
YSA	Yapay Sinir Ağları
σ	Gauss dağılımının standart sapması

1. GİRİŞ

1.1. Tezin Amacı, Kapsamı ve Özgünlüğü

Son yıllarda teknolojinin gelişimine paralel olarak işlemci hızlarının artması, milyarlarca verinin çok kısa zamanlarda işlenmesine olanak tanımıştır. Bu teknolojik iyileşmeler ile literatürde derin öğrenme olgusu ortaya çıkmış, milyarlarca verinin işlenip aralarında anlamlı bir örüntü yakalanarak insanlığa faydalı çıktılar üretmesi amaçlanmıştır [1].

Özellikle 2010'lu yıllardan sonra oldukça popüler hale gelen derin öğrenme algoritmalarının pek çok alanda uygulaması bulunmaktadır. Bu uygulama alanlarının en başında biyomedikal alan ile savunma sistemleri olduğunu söylemek mümkündür. Biyomedikal alana bakılacak olursa; MR (Manyetik Rezonans), X-ray ve bilgisayarlı tomografi (Computed Tomography, CT) görüntüleri kullanılarak hastalık ile kırık tespitinin, biyolojik veri kestiriminin, doku ve organ bölütlemesinin (segmentasyonunun), eksik veri tamamlanmasının ve daha birçok uygulamanın artık derin öğrenme algoritmaları sayesinde yüksek başarı oranları ile gerçekleştirildiği söylenebilir [2-5]. Ancak bu uygulamaların neticesinde, ulaşılan başarıların çok büyük bir çoğunluğu insandan alınan görüntülerle elde edilirken, hayvan anatomisi üzerine yapılan uygulamalarda derin öğrenme algoritmaları pek fazla kullanılmamıştır. Oysaki insan vücudunda görülen hastalık ve yaralanmalara, hayvanlarda da rastlamak pek mümkündür. Öte yandan, hayvan sağlığı gerek evcil hayvan besleyen insanlar gerekse de gıda-taşımacılık vb. amaçlarla hayvan sahibi olan insanlar için göz ardı edilemeyecek bir önem arz etmektedir. Bu tez çalışmasında da mühendislik adına hayvan sağlığına katkıda bulunma amacı güdülmektedir.

İnsan tabanlı veri setleri ile biyomedikal görüntü işlemede temel amaç sınıflandırma, nesne algılama, veri tamamlama ve bölütleme olarak kategorize edilebilir [6-9]. Bu amaçlı yapılan çalışmaların genelinde MR, X-ray ve CT görüntüleri kullanılmış, görüntülerdeki örüntüler çıkarılarak bahsedilen amaçlara ulaşılmaya çalışılmıştır. Özellikle kemiklerdeki kırıkların tespit edilmesi yine bu alanda en çok çalışılan konulardan biridir [10,11]. İnsanların farklı anatomik bölgelerindeki kemik kırıklarının varlığı neredeyse uzman bir ortopedist kadar derin öğrenme algoritmaları tarafından saptanabilmektedir [12]. İnsan anatomisi üzerinde algoritmalar tarafından ulaşılan bu saptama başarıları, aynı ya da benzer algoritmalarla hayvanlarda da söz konusu olabileceği sezgisini doğurmuştur. Özellikle

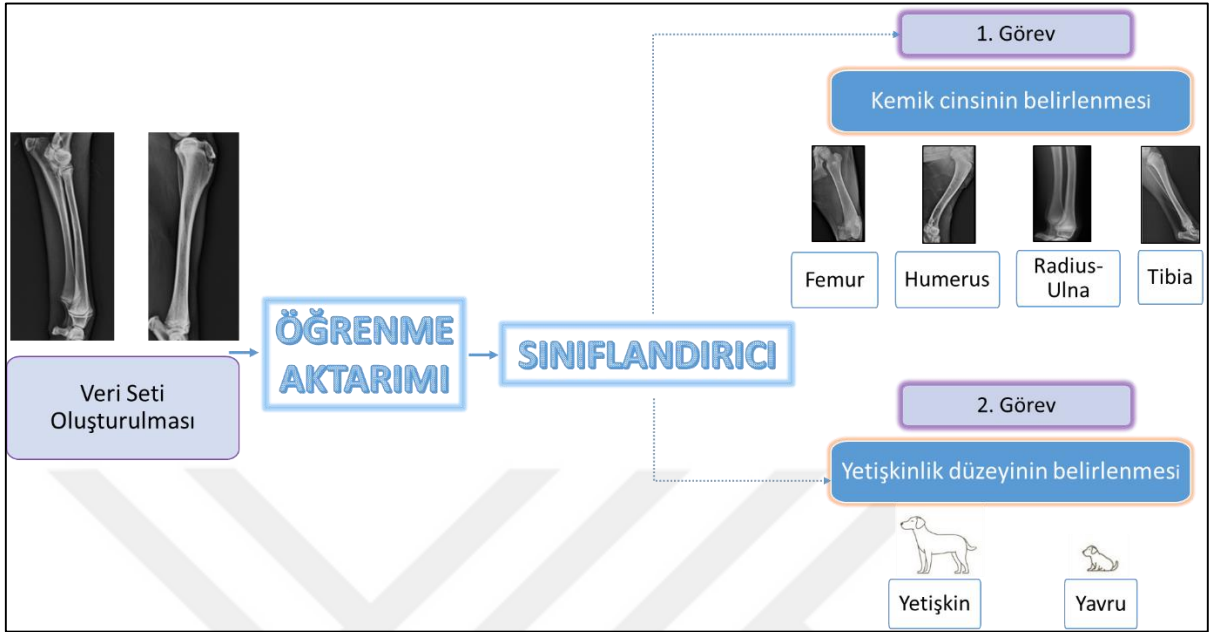
literatürde, bu alandaki eksikliğin fark edilmesi bu tez konusunun en büyük motivasyon kaynağı olmuştur.

Aynı beşeri tıp gibi, veteriner tıbbı da ortopedi, kardiyoloji, üroloji ve viroloji gibi farklı uzmanlık alanlarına sahiptir. Bu doktora tezinin başlıca amacı, ortopedi veya cerrahi konusunda uzman eğitimi olmayan veteriner hekimlere yardımcı çıktılar üretebilmektir.

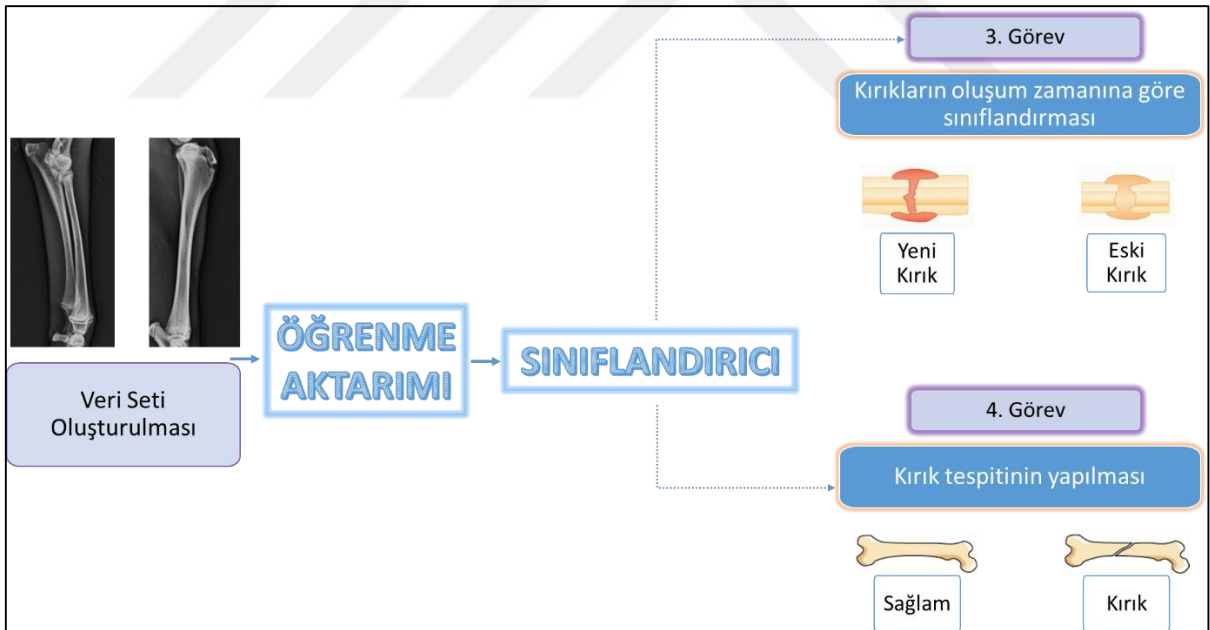
Derin öğrenme algoritmaları, öğrenme aşamasında geleneksel makine öğrenmesi algoritmalarına oranla çok daha fazla veriye ihtiyaç duyar [13]. Veri sayısı, çeşitliliği ve verinin doğru etiketlenmiş olması bir algoritmanın başarısını etkileyen en önemli faktörler olarak geçmektedir. Bu da veri setinin olabildiğince çeşitli olması, güvenilir bir kaynak tarafından ayrılması ve verilere uygun algoritmaların uygulanması anlamına gelmektedir. Bu bağlamda, Ankara Büyükşehir Belediyesi Sokak Hayvanları Geçici Bakım Evi'nden alınan, köpeklere ait X-ray görüntülerini içeren geniş kapsamlı bir veri seti; alanınca uzman veteriner bir ortopedist tarafından uzun kemiklere ve bu kemiklerdeki kırığın çeşidine göre etiketlenmiştir. Amaç, derin öğrenme algoritmaları ile köpeklere ait X-ray görüntülerinden uzun kemiğin çeşidini belirlemek, kemikteki kırığın varlığını saptamak ve var olması durumunda da kırığı sınıflandırabilmektedir. Ayrıca kırık kemiklere ait X-ray görüntülerinin incelenerek kırığın meydana gelme zamanının belirlenmesi ile sağlam kemiklere ait X-ray görüntülerinden köpeğin yetişkinlik düzeyinin belirtilmesi de tez kapsamında yapılan çalışmalar arasında yer almaktadır. Bu alandaki pek çok çalışma gibi, bu çalışmada da öğrenme aktarımı (transfer learning) yöntemi tercih edilmiş, pek çok farklı Evrişimsel Sinir Ağları (Convolutional Neural Network, CNN) mimarisi irdelenmiştir [14,15]. Elde edilen başarımların ise iyileştirilmesi adına araştırmalar ve analizler yapılmıştır. Yapılan çalışmaların anlaşılabilirliğini artırmak adına oluşturulan yazılım iskeletleri Şekil 1.1, 1.2, 1.3 ve 1.4'te verilmiştir.

Yapılan literatür taramasında, hayvanlarda kırık tespiti yapan çalışmalara rastlanmasına karşın [16-18]; kemik çeşidi ve kırıklarını sınıflandırmaya, kırık zamanını tespit etmeye ve köpeğin yetişkinlik düzeyini sahip olduğu X-ray görüntüsüne göre belirlemeye yönelik yapılmış bir çalışmaya yazarın bilgisi dahilinde rastlanamamıştır. Literatürün görüntü işleme algoritmaları tarafından fazla inceleme fırsatı bulamamış bu alanlarına ışık tutmanın, tezin en faydalı çıktısı olacağı düşünülmektedir. Ayrıca doktora tezi kapsamında meydana

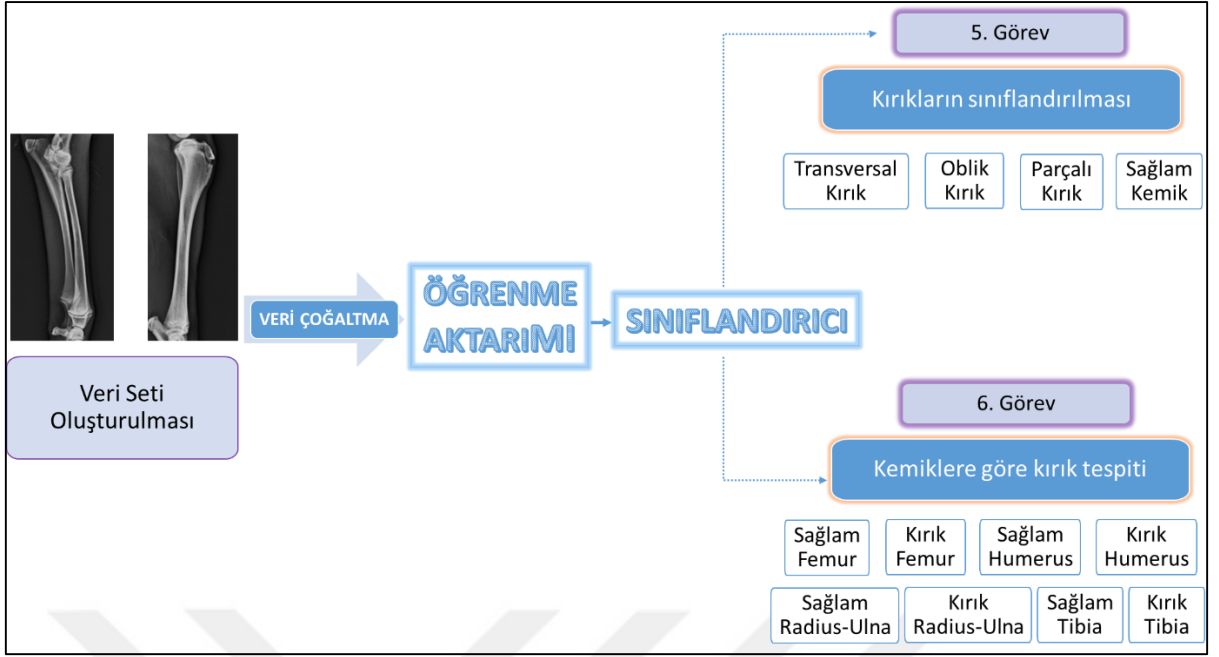
getirilen kapsamlı ve özgün veri setinin diğer arařtırmacılara faydalı olabilmesi adına çevrimiçi bir platformda paylaşılması ise tezin bir başka önemli faydası olacaktır.



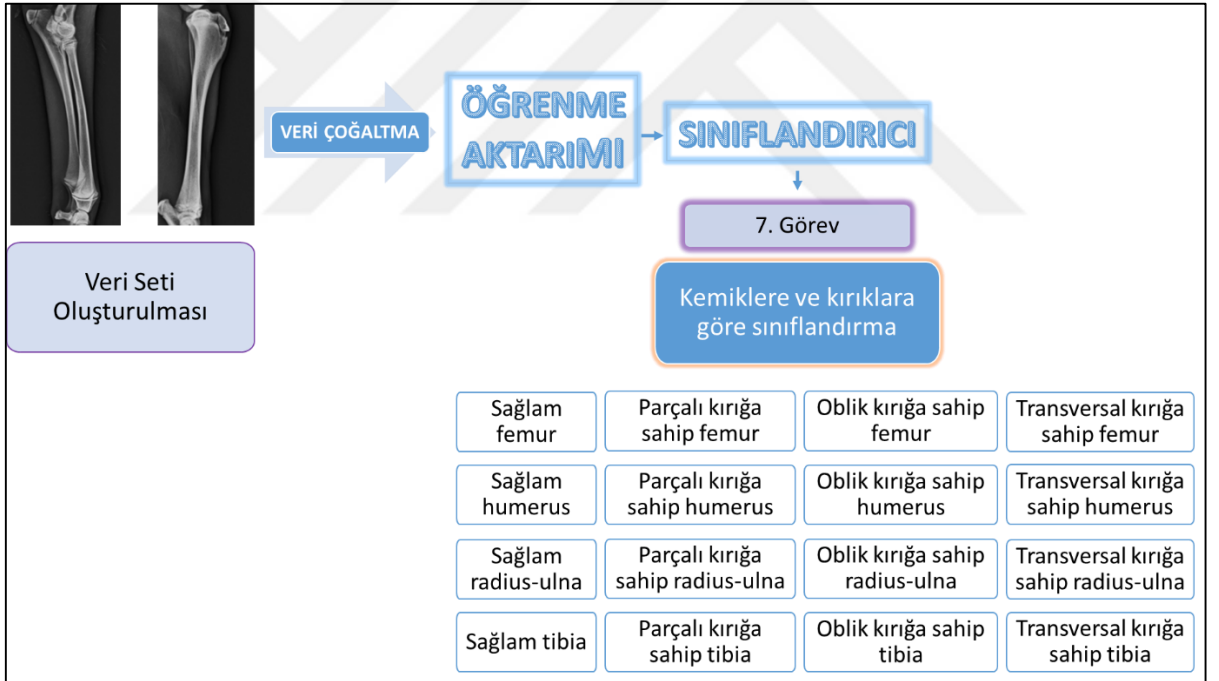
Őekil 1.1. Yazılım iskeleti: 1. ve 2. görevler.



Őekil 1.2. Yazılım iskeleti: 3. ve 4. görevler.



Şekil 1.3. Yazılım iskeleti: 5. ve 6. görevler.



Şekil 1.4. Yazılım iskeleti: Temel görev.

1.2. Problem Tanımı ve Motivasyon

Veteriner tıpta kırık; kemik veya kırıldak doku bütünlüğünün bozulması olarak adlandırılır. Kemiklerde kırığı oluşturan nedenlerin başında travmatik etkiler gelir [19].

Başlıcaları:

- Kemik üzerine aniden fazla ağırlığın binmesi,
- Uzun kemiklerin eksenine etrafında zorlayıcı dönme hareketleri,
- Şiddetli aktif ve pasif kas kontraksiyonları (kasların kasılması hareketi)'dir.

Kırıklar farklı şekillerde meydana gelebilir. Kırıkların sınıflandırılması konusu ise uygun tedavi prosedürünü belirlemede büyük önem arz etmektedir. Kemik kırıkları sınıflandırılırken aşağıdaki maddeler baz alınabilir:

a) Kırık yapısına ve etkiyen kuvvet mekanizmasına göre: Normal yapıdaki kemiğe etkiyen kuvvetle meydana gelir. Etkiyen kuvvet şekline göre ikiye ayrılır. Eğer kuvvet, kemiğe diklemesine geldiği yerde kırık oluşturuyorsa direkt kırıklar; geldiği noktadan uzakta kırık meydana getiriyorsa direkt olmayan (indirekt) kırıklar olarak isimlendirilir.

b) Deri yaralanmaları ve kırıkların dış ortam ile olan ilişkisine göre: Kemiğin deri dışındaki mevcudiyetine göre açık (komplike) kırıklar ve kapalı (basit) kırıklar olmak üzere iki sınıfta incelenir.

c) Kırık derecelerine göre: Tam ve tam olmayan kırıklar olarak ikiye ayrılır. Tam kırıklarda, kemik bütünlüğü tamamen bozularak en az iki parçaya ayrılırken; tam olmayan kırıklarda, kırık kemikten tam ayrılamamıştır. Kemiklerdeki çatlaklar, epifiz ayrışmaları vb. durumlar tam olmayan kırık çeşidinin başlıca örnekleridir.

d) Kırık sayısına göre: Kırık hattı sayısına göre ayrılmasıdır. Tek kırık çizgili olanlar, iki kırık çizgili olanlar, parsiyel kırıklar, parçalı komminütif kırıklar ve segmental kırıklar olarak çeşitlendirilebilir.

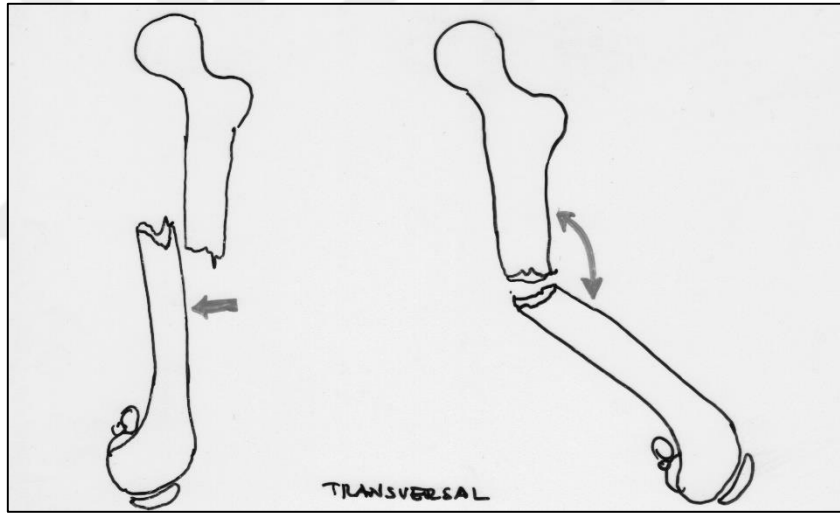
e) Kırık hatlarının yönü: Enlemesine (transversal), eğrilemesine (diyagonal, oblik), helezoni (spiral) ve parçalı kırıklar olarak tasniflenir.

f) Anatomik olarak yerleşme yerime göre: Proksimal (yakın), diafiz (uzun kemiklerin gövdesi) ve distal (uzak) kırıklar olarak kırığın meydana geldiği lokasyona göre üç grupta incelenir.

g) Kemik yapısına göre: Spongiosoz kısım (kemiğin içinde kalan süngerimsi yapıya sahip bir bölüm) kırıklar ve kortikal kısım (yoğun ve sıkı yapıda olan, kemiğin %80'ini oluşturan bölüm) kırıklar olarak ikiye ayrılır [19].

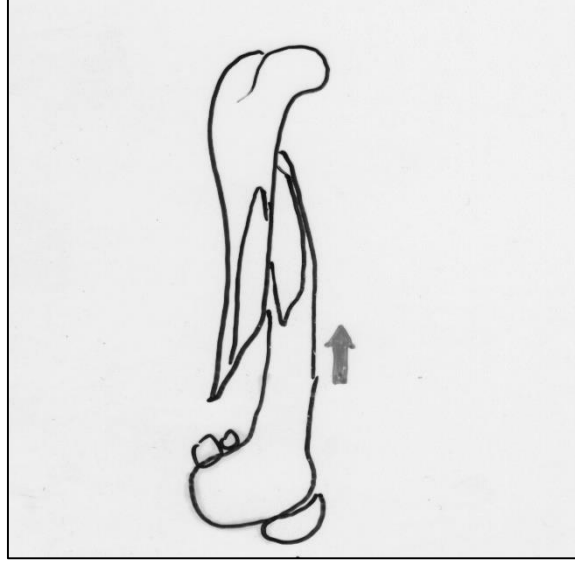
Tez kapsamında yapılan çalışmalarda, gerçek hayat problemlerine çözüm üretme, veteriner hekimlere yardımcı bir araç geliştirme hedefi gerçekleştirilmeye çalışılmıştır. Bu sebeple, veri setini etiketleme işlemlerinde, gerçek hayatta hayvanlarda en sık karşılaşılan ortopedi kırıkları esas alınmıştır. Uzman veteriner ortopedist görüşleri değerlendirilerek, köpeklerde en sık vaka bulan kırık çeşitleri ile sınıf etiketleri oluşturulmuştur. Kırık hatlarının yönüne göre bu etiketler:

1.2.1. Transversal kırıklar: Enlemesine kırık olarak da isimlendirilir. Kırık çizgisi kemiğin uzun eksenine, 30 dereceden fazla olmayacak şekilde diktir. Görseli Şekil 1.5'te verilmiştir [19].




Şekil 1.5. Transversal kırık [19].

1.2.2. Oblik (diyagonal) kırıklar: Bu tip kırıklara şekil benzerliğinden dolayı flüt ağzı kırığı da denir. Bükülme kuvveti ile oluşurlar. Kırık çizgisi ile kemiğin uzun eksenini arasındaki açı, 30 dereceden fazladır. Görseli Şekil 1.6'da verilmiştir [19].



Şekil 1.6. Oblik kırık [19].

- 1.2.3. **Çok parçalı kırıklar:** Kırık hatta birden fazla olan kırık çeşididir. Genellikle doğrudan kuvvet etkisiyle meydana gelirler. Görseli Şekil 1.7’de verilmiştir [19].



Şekil 1.7. Çok parçalı kırıklar [19].

Veteriner hekimler, ortopedi operasyonları öncesinde bazı durum değerlendirmeleri yaparlar. Bu değerlendirmeler, muayeneye sistemik yaklaşım açısından önem taşımaktadır. Değerlendirmede temel alınan kıstaslar şu şekilde maddelendirilebilir [19]:

- Vakanın karmaşık yapısı,

- Son travmanın anamnezi (veteriner hekimin teşhis koyma amacıyla hasta sahibine sorduğu sorular sonucu elde ettiği hastalık öyküsü),
- Hayvanın kullanım amacı,
- Hasta sahibinin ekonomik durumu.

Tez kapsamında yapılan kırık çeşitlerini sınıflandırma çalışmaları, değerlendirme kriterlerinden biri olan vakanın karmaşıklığı konusunda fikir vermesi sebebiyle veteriner hekimlere yol gösterici özelliğe sahiptir.

1.3. Literatür Taraması

Günümüzde, başta biyomedikal alan olmak üzere birçok çalışma alanı derin öğrenme olgusundan olumlu yönde etkilenmiştir [20]. Yapılan çalışmalarda derin öğrenme algoritmaları sayesinde yüksek başarı oranları ile hastalık ve kırık tespiti, organ ve doku bölütlemesi ve daha birçok uygulama, inceleme alanı bulmuştur [21,22]. Bu yayınlar detaylı incelendiğinde ise, araştırmaların genel olarak beşeri tıp adına yapıldığı, veteriner tıbbın yeterli inceleme alanı bulamadığı göze çarpmaktadır. Oysaki veteriner hekimliğin önemi, şu anonim cümle ile vurgulanmıştır: “İnsan hekimliği insanlar için ise veteriner hekimlik insanlık içindir.”

Literatürde, mühendislik ile veterinerlik tıbbı birleştiren bazı disiplinler arası çalışmalara rastlamak mümkündür. Bunlardan ilkinde domuzlar üzerine yapılan bir çalışma örnek olarak verilebilir [23]. Çalışmadaki amaç, CT taramasından elde edilen görüntüler ile domuz iskeletini otomatik olarak bölütleyebilmektir. Evrişimsel Sinir Ağları uygulayarak %95 başarı elde eden araştırmacılar, derin öğrenme yöntemlerini kullanmanın başarıyı artırdığını ve kontrol konusunda insana olan ihtiyacın azaldığını iddia etmişlerdir. Araştırmacılar, çalışmalarına ait bulguların domuz yetiştiriciliğinde kullanılabileceğini vurgulamışlardır.

Başka bir makalede McEvoy ve arkadaşı, 60 farklı köpeğin ventrodorsal pelvis radyografi görüntülerini kullanarak kısmi en küçük kareler ayrıştırıcı analizi (Partial Least Squares Discriminant Analysis, PLS-DA) ve yapay sinir ağları (YSA) olmak üzere iki makine öğrenme yöntemi ile kalça eklemine içeren görüntü bölgelerini otomatik olarak

belirlemeyi amaçlamıştır. 256 adet toplam görüntünün 200 tanesi eğitim için kullanılmış ve kalan test görüntüleri ile de alınan sonuçların umut verici olduğu vurgulanmıştır [24].

Vinicki ve arkadaşları, veteriner tıp alanında derin öğrenme yöntemlerini incelemek amacıyla Tek Atış Detektörü (Single-Shot Detector, SSD) ve CNN mimarilerini kullanarak kedi kanı yaymalarının mikroskop görüntülerinden retikülosit sayısını tahmin etmeye çalışmıştır. Kullandıkları toplam 800 görüntü ile %98,7 başarı elde etmişlerdir [25].

Bir başka çalışmada, Banzoto ve arkadaşları CNN mimarisini kullanarak köpeklere ait MR görüntülerindeki bir lezyonun meninjiyom ya da gliom olduğunu tahmin etmeyi hedeflemiştir. Çalışmalarının sınıflandırma doğruluğu %94 olarak belirtilmiştir [26].

Arsomngern ve çalışma ekibi hem köpeklerden hem de kedilerden alınan toplamda 2862 adet göğüs röntgen görüntüsünü kullanarak, bu hayvanlarda bir akciğer lezyon problemi olup olmadığını Evrişimsel Sinir Ağları kullanarak araştırmıştır. Araştırmadan alınan sonuçlara göre, vakaların %79,6'sında lezyonu doğru bir şekilde tespit ettiklerini göstermişlerdir [27].

143 adet köpek X-ray görüntüsünden 124 adedini eğitim, kalan 19 adedini ise test için kullanarak uzun kemiklerden biri olan tibia kırıklarının tespiti üzerine çalışılan bir yayında ise araştırmacılar, SSD MobileNet-v2 yöntemini kullanmışlardır. Araştırmacılar, çalışmalarındaki F-skor değerini 0,68 olarak elde etmişlerdir [17]. Yine aynı çalışma grubu, görüntü sayısını artırıp kırık tespitine yönelik olarak farklı derin öğrenme mimarilerini uygulayarak F-skor değerini yükseltmiş, tibia kemiğindeki kırık tespiti adına umut verici sonuçlar elde edildiğini vurgulamışlardır [18].

Bunlar dışında hayvanlar üzerine yapılan bir başka derin öğrenme içerikli çalışma ise Xiaoping Huang ve arkadaşları tarafından inek kuyruklarını tespit etmeye yöneliktir. Bölge Tabanlı CNN (Region Based Convolutional Neural Network, R-CNN) tekniği kullanılarak geliştirilen çalışmanın, ineklerin kas kapasitesini gösteren bir parametre olan vücut kondisyon skorunu (Body Condition Score, BCS) belirlemek için yararlı bir çalışma olduğu iddia edilmiştir [28].

Beşeri tıp adına da benzer çalışmalara örnek göstermek mümkündür. Örneğin ortopedi alanında yapılan bir çalışmada, çocuklardaki distal tibial kırıkların saptanmasında CNN

yönteminin başarısı incelenmek istenmiştir. 980 adet görüntü, Inception-v3 mimarisi uygulanarak analiz edilmiş ve %95,9'luk bir başarı performansı yakalanmıştır [29].

Amacı menisküs yırtığı varlığına göre MR görüntülerini sınıflandırmak olan bir çalışmada Bölge Tabanlı CNN yöntemi ile %90,6'lık başarı elde edildiği gözlenmiştir [30].

Farklı hastalardan alınan X-ray görüntüleri ile hazırlanan geniş kapsamlı bir veri seti, lojistik regresyon, L2 ceza parametresi ile lojistik regresyon, CNN ve k-NN (k-Nearest Neighbour) olmak üzere dört farklı denetimli/denetimsiz öğrenme algoritmalarıyla test edilmiş, en yüksek doğruluk değerine k-NN algoritması ile ulaşılmıştır [31].

İnsanlarda, kol kırıklarının tespitinde başarıyı artırma amacıyla Üretken Düşmanca Ağlar (Generative Adversarial Networks, GAN) yapılarının da uygulandığı çalışmalar mevcuttur. Bu konuda örnek teşkil edebilecek bir çalışmada araştırmacılar, AC-GAN (Auxiliary Classifier-GAN) tabanlı yöntemlerle %91,2 başarı elde etmişlerdir [32].

Beyaz ve arkadaşları, derin öğrenme tekniklerini kullanarak insandaki femur boyun kırığını saptamayı amaçlamışlardır. 1341'i kırık, 765'i sağlam olacak şekilde çalışılan 2106 femur boyun grafisi ile CNN mimarisine ait duyarlılık ve özgüllük oranları sırasıyla %83 ve %73 olarak hesaplanmış, CNN mimarisinin hiper parametreleri genetik algoritma ile optimize edilmiştir. Farklı boyuttaki veriler ile eğitim işleminin tekrarlanması sonucunda, küçük boyuttaki verilerle yüksek başarılar elde edilebileceği, söz konusu çalışmada vurgulanmıştır [33].

İnsan bileğini kırık ve sağlam olacak şekilde iki sınıfa ayıran bir başka çalışmada; araştırmacılar 695'i kırık, 694'ü sağlam olmak üzere toplamda 1389 görüntü ile çalışmışlardır. Inception-v3 derin ağ mimarisi ile %95,4'lük başarı elde edilen çalışma, öğrenme aktarımı yönteminin medikal görüntülerde başarılı sonuçlar verdiğini ispat etmiştir [34].

Benzer şekilde, insanlarda femur kırıklarını normal ya da atipik olmak üzere iki sınıfa ayıran bir çalışmada ise, 397'si atipik, 399'u normal femur kırığından oluşan veri kümesiyle, önceden eğitilmiş derin ağlar test edilmiştir. VGG-19, ResNet-50 ve Inception-v3 mimarilerinden sırasıyla %82,7, %89,4 ve %90,5 başarı oranları elde edilmiştir. Yazarların önerdikleri metot ile bu oranlar sırasıyla %92,2 %93,4 ve %94,4 seviyelerine kadar çıkarılmıştır [35].

İncelenen farklı çalışma alanlarından biri de kemik yaşı kestirimidir. İnsan tabanlı veri setleri ile yapılan çalışmalar incelendiğinde, dikkat çeken bir çalışmanın S. Wang ve ekip arkadaşlarının 2018 yılında yaptığı araştırma olduğu fark edilmiştir. Söz konusu çalışmada insan iskelet sisteminin olgunluğu, el ve bilek kemiklere ait MR görüntülerinin incelenmesi ile tahmin edilmeye çalışılmıştır. Kemik yaşının otomatik olarak kestirimi üzerine geliştirilen bu çalışmada, R-CNN tabanlı algoritmalar kullanılmış ve sonucunda %92 sınıflandırma başarısı radius kemiği için, %90 sınıflandırma başarısı ise ulna kemiği için elde edilmiştir. Çalışmada toplamda 1101 adet insan el ve bilek kemiğine ait MR görüntüsü kullanılmış ve yazarlar çalışmalarının ortopedi üzerine oldukça faydalı olabileceğini belirtmişlerdir [36].

Yine insan el ve bilek kemik görüntülerinin incelenerek yapıldığı bir çalışmada, kemik yaşının birer yıl ara ile tahmin edilmesi hedeflenerek CNN ağ yapıları kullanılmıştır. Çalışmada, öğrenme aktarımı yöntemi ile iki farklı regresyon yöntemi denenerek ortalama hata hesaplanmıştır. VGG-16 derin öğrenme ağı çıktısının 2 boyutlu evrişimler ile daha detaylı incelenmesinin başarıyı artırdığı sonucuna varılmıştır [37].

Beşeri tıp üzerine yapılan örnek çalışmaların sayısı artırılabilir; ancak literatürde hayvan sağlığını mühendislik çözümleriyle ayrıntılı olarak inceleyen çalışmaların sayısı az olduğundan, bu doktora tezi kapsamında yapılan çalışmalar veteriner hekimlere yardımcı bir araç olarak kullanılabilir niteliktedir. Yapılan çalışmalar, veteriner hekimlere ameliyat öncesinde hazırlık yapma fırsatı verebilecek, hekimlere teşhis konusunda da kılavuzluk ederek yardımcı olabilecek kapsamdadır.

2. MATERYAL VE METOT

2.1. Veri Seti

Bu doktora tezi kapsamında, Ankara Büyükşehir Belediyesi Sokak Hayvanları Geçici Bakım Evi'nden alınan, köpeklere ait X-ray görüntüleri içeren geniş kapsamlı bir veri seti oluşturulmuştur. X-ray görüntüleri, Şekil 2.1'de gösterilen Hasvet firmasına ait Ecoray ultra HF100 veteriner röntgen cihazı kullanılarak kasetlere çekilmiş, Şekil 2.2'de gösterilen Fujifilm markasının FCR PRIMA T2 modeline ait masaüstü okuyucu ünitesi sayesinde hızlıca okutularak dijital görüntüler elde edilmiştir. FVS-1000 adındaki bir ara yüz programı vasıtasıyla da bu dijital veriler detaylı olarak incelenmiştir. FVS-1000 programında incelenebilen görüntüler ise son aşamada kırılarak .png uzantılı olacak şekilde uygun etiket ile ayrı dosyalarda kaydedilmiştir.



Şekil 2.1. Ecoray ultra HF100 veteriner röntgen cihazı.



Şekil 2.2. Fujifilm FCR PRIMA T2 görüntüleme cihazı.

Derin öğrenme algoritmalarında, eğitim işlemi için fazla veriye ihtiyaç duyulur ve verilerin niteliği çalışmaların başarısını doğrudan etkiler. Bu temelin sağlam atılabilmesi adına veri setinin oluşturulma ve etiketlendirme aşamalarında, alanında uzman ortopedist veteriner ile çalışılmıştır.

Köpeklerde iskelet sistemini belirten bir görsel Şekil 2.3'te sunulmuştur. Şekil 2.3'te detaylı olarak belirtilen kemiklerden sadece uzun kemik sınıfına girenler incelenmiştir. İncelenen görüntülerden 671 tanesi femur, 264 tanesi humerus, 268 tanesi radius-ulna ve kalan 554 tanesi de tibia olacak şekilde toplamda 1757 adet görüntü, köpeklerdeki uzun kemiğin cinsine göre dört farklı sınıfa ayrılmıştır. 620 görüntü ise, alan dışı ya da görüntüleme esnasındaki yapılan hatalarla kaydedilen görüntüler olup bu veri setine dahil edilmemiştir.


Kemiğin kırık veya sağlam olmasına göre; aynı X-ray görüntüleri 479 tanesi kırık; 1549 tanesi sağlam kemik olacak şekilde ayrı bir veri seti daha oluşturulmuştur. Sonrasında kırık olan kemiklerin, kırık çeşidine göre ise 120 tanesi transversal, 88 tanesi oblik, kalan 154 tanesi de çok parçalı kırık etiketi ile 1549 adet sağlam kemiklerden oluşan bir başka veri seti daha meydana getirilmiştir. Veri kümesini oluşturulan etiketli görüntülere ait örnekler ise Şekil 2.4 ile Şekil 2.5'te verilmiştir. Bu etiketli veriler harmanlanarak farklı veri setleri oluşturulmuş, her bir çalışma için oluşturulan veri setlerine ait detaylara Bölüm 3'te yer verilmiştir.

Doktora tezi için meydana getirilen veri seti, içerdiği hasta sayısı ve hayvan sağlığını farklı bakış açılarıyla ele alınışı açısından oldukça kapsamlı ve özgündür. Oluşturulan veri seti, diğer araştırmacıların da faydalanabilmesi adına çevrim içi veri paylaşım platformunda paylaşılmıştır.


2.2. Kullanılan Görüntü Ön İşleme Yöntemleri

Veri setinde yer alan X-ray görüntüleri boyut, parlaklık ve çekim açısı olarak homojen bir görünüme sahip değildir. Bu nedenle öncelikli olarak etiketlenen tüm görüntüler, kullanılan alt çalışmalarda RGB olarak aynı boyuta getirilerek işlem yapılmıştır. Görüntü boyutu kullanılan alt çalışmalarda farklılık göstermektedir.


Parlaklık ve çekim açısından kaynaklanan heterojen duruma ise; problemi, gerçek hayat probleminde yakınsatmak amacıyla ön işleme yapılmamıştır. Veri setindeki farklı boyut, parlaklık ve çekim açılarını gösteren örnek görüntülere Şekil 2.6'da yer verilmiştir. Şekildeki tüm görüntüler sağlam femur kemiğine aittir.



Şekil 2.3. Canine (köpek) iskelet sistemi [38].



Şekil 2.4. Veri setinde kemik çeşidine göre etiketlenirilen sağlam görüntüler. a) femur, b) humerus, c) radius-ulna ve d) tibia.



Şekil 2.5. Veri setinde humerus kemiğine ait kırık çeşitlerine göre etiketlenilmiş örnek görüntüler. a) transversal, b) oblik ve c) çok parçalı kırık.



Şekil 2.6. Sağlam femur kemiğine ait farklı boyut, parlaklık ve çekim açısındaki örnek görüntüler.

2.3. Veri Çoğaltma Yöntemleri

Derin öğrenme algoritmaları için görüntü toplama ve hazırlama aşamaları oldukça maliyetlidir ve başarılı bir çıktı elde edebilmek için fazlaca etiketli veri gerektirir. Bu

nedenle, genelde görüntü ön işleme yöntemlerinden biri olarak sayılan veri çoğaltma (data augmentation) işlemine sıkça başvurulmaktadır. Veri çoğaltma ya da çoklama kısaca, sınırlı veriden daha fazla veriye geçiş olarak tanımlanabilir [39]. Bu işlem sinir ağlarında zaman zaman karşılaşılan ezberleme (overfitting) probleminin önüne geçilmesine ve dengesiz veri kümelerini eşitleyerek performans artırımına yardımcı olur.

Literatürde pek çok görüntü çoğaltma yöntemi bulunmaktadır. Bunları geleneksel yöntemler ve derin öğrenme tabanlı yöntemler olarak ikiye ayırmak mümkündür. Hangi yöntemin daha iyi olduğuna dair ise kesin bir bulgu yoktur. Çünkü yöntemler uygulanan veri seti ve çalışmanın amacına göre farklı başarımlar göstermektedir. Örneğin yapılan bir çalışmada, görüntü sınıflandırma amacıyla geleneksel yöntemler ile derin öğrenme tabanlı veri çoğaltma yöntemleri karşılaştırılmıştır. Görüntüleri kırpma, döndürme ve çevirmek gibi geleneksel teknikler ile derin öğrenme tabanlı GAN yapısı uygulanmış, geleneksel veri çoğaltma yöntemlerinin daha etkili olduğu gösterilmiştir [40].

Başka bir araştırma makalesinde, veri çoğaltma metotlarından yatay çevirme, rastgele kesme ve temel bileşen analizi (Principal Component Analysis, PCA) yöntemleriyle çalışılmıştır. Çalışma sonucunda, çoğaltma işlemlerinin sınıflandırma performansına pozitif yönde etki ettiği gösterilmektedir [41].

Geleneksel yöntemlerle ilgili daha fazla çalışmaya örnek vermek mümkündür [42-46]. Ancak tüm bu yöntemler ile elde edilen sonuçlar veri kümelerine bağlıdır ve literatürde köpeklere ait X-ray görüntülerini içeren kapsamlı bir veri kümesi kullanarak yapılan çalışmalara rastlamak çok zordur. İlerleyen bölümlerde anlatılan alt çalışmalarda, veri kümesi üzerindeki etkisini incelemek amacıyla bazı geleneksel veri çoğaltma yöntemleri uygulanmıştır Bunlar:

1. Görüntülerin çevrilmesi (flipping)
2. Görüntülerin döndürülmesi (rotating)
3. Görüntülerin parlaklığının değiştirilmesi (brightness)
4. Görüntülerin kontrastının değiştirilmesi (contrast)
5. Görüntüleri bulanıklaştırma (blurring)


Bu geleneksel yöntemlerin, sınıflandırma performansına ait detaylı analizleri ve karşılaştırmalı çalışmaları Bölüm 3’te sunulmuştur. Bahsedilen bu geleneksel veri çoğaltma yöntemleri, az maliyetli olup uygulamaları kolaydır.

2.3.1. Çevirme (flipping): Görüntüleri yatay ve dikey olarak çevirme işlemidir. Yöntem, ilerleyen alt çalışmalarda yatay, dikey ve her ikisi beraber olacak şekilde uygulanmıştır.

2.3.2. Rotasyon (rotation): Görüntüleri belirli bir açı ile döndürme işlemidir. Pozitif açı uygulaması görüntüleri sağ tarafa döndürürken; negatif açılar görüntüleri sol tarafa döndürür. Döndürme işleminin ardından görüntülerin boyutlarında değişiklik meydana gelir. Bu nedenle uygulamanın ardından görüntüler tekrar orijinal boyutlarına çevrilirler.

2.3.3. Parlaklık (brightness) değişimi: Görüntülerin parlaklık ayarlarıyla oynanarak çoklanması işlemidir. İşlem sonucunda görüntüler daha açık veya daha koyu hale gelir.

Gri seviyeli bir görüntü matrisinde piksel değerleri, 0-255 arasında değerler alır. Bu değerlerin 0’a yakınsaması görüntü rengini siyaha; 255 değerine yakınsaması ise görüntü rengini beyaza çevirir. Parlaklık değişim işlemi, görüntünün her piksel değerinin parlaklığının artırılması veya azaltılması şeklinde gerçekleşir. Dolayısıyla görüntünün her piksel değeri üzerine bir katsayı eklenmesi işlemi görüntü parlaklığını artırırken; katsayıyı çıkarma işlemi ise parlaklığı azaltıcı etki yapar. Veri setinden seçilen oblik kırığa sahip bir kemik görüntüsünün parlaklık değişimleriyle elde edilmiş çıktılarına Şekil 2.7’de yer verilmiştir.



Şekil 2.7. Parlaklık değişimi sonucu veri setinden elde edilen görüntülere örnekler
a) orijinal görüntü, b) orijinal görüntü matrisine 50 değerinin eklenmesiyle oluşan çıktı, c)
orijinal görüntü matrisinden 50 değerinin çıkarılmasıyla oluşan çıktı.

2.4.4. Zıtlık (kontrast) deęişimi: Görüntü içeriklerini ayırt edebilmek amacıyla renk çeşitlilięi, farkı ve parlaklık derecesinin ayarlanması işlemidir.

Veri setindeki görüntülerin kontrast limitlerinin deęiştirilmesiyle veri çoęaltma işlemi gerçekleşmiştir. Gri seviyeli girdi görüntülerinde, çıkış görüntüsündeki deęerlerle eşlemek istenilen kontrast sınırları (0-1) arasında olmalıdır. Tez kapsamında yapılan çalışmalarda bu limitler deneme yanılma yöntemi ile üç farklı şekilde işleme alınmıştır. İlki, girdi ve çıktı görüntülerine ait kontrast limitlerinin sırasıyla (0.1 - 0.6) ile (0.01 - 0.8) olarak alınması; dięeri bu deęerlerin (0.2 - 0.7) ile (0.1 - 0.9) olarak alınması; ve sonuncu limitlerin ise tam tersine döndürülerek (0 - 1) ile (1 - 0) olarak alınmasıdır.

2.3.5. Bulanıklaştırma (Blurring): Görüntülerin netlik ayarlarıyla oynanarak çoklanması işlemidir. İşlem sonucunda görüntüler, orijinal görüntüden daha bulanık hale gelir. Bu işlem, görüntülerden yüksek frekanslı içeriğin (gürültü, kenar gibi) kaldırılmasına neden olur. Bu sayede, gürültü içerikli görüntülerde daha kullanışlı bir uygulama olarak görülür.


Görüntüyü bulanıklaştırmak için farklı teknikler mevcuttur. Bunlar: ortalama alma (averaging), Gauss filtresi uygulama (Gaussian blurring), medyan filtresi uygulama ve bilateral filtreleme olarak incelenebilir.

Tez kapsamında yapılan bulanıklaştırma işlemlerinde Gauss filtresi kullanılmıştır. Gauss filtresi, girdi görüntülerinin gürültüsünü ve ihmal edilebilir detaylarını azaltmaya yarayan bir alçak geçiren filtre olarak düşünülebilir [47]. İki boyutlu bir Gauss filtresi matematiksel olarak (2.1) ile ifade edilebilir.

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2.1)$$


Eşitlikte σ , dağılımın standart sapma deęerini ifade ederken; x ve y parametreleri görüntü matrisindeki konum endeksleridir. Sigma deęerinin artması, görüntüdeki yüksek frekanslı bilgi içeriğinin azalmasına neden olur [47].

Bir görüntü üzerinde uygulanan veri çoęaltma tekniklerinin çıktıları Şekil 2.8'de örnek olarak verilirken; tez çalışmalarında kullanılan örnek bir görüntüden elde edilen çıktılar ise Şekil 2.9'da verilmiştir.



Şekil 2.8. Veri çoğaltma işlemi sonucu elde edilen çıktı görüntülerine örnekler [48].

a) orijinal, b) çevirme, c) rotasyon, d) parlaklık değişimi, e) bulanıklaştırma.



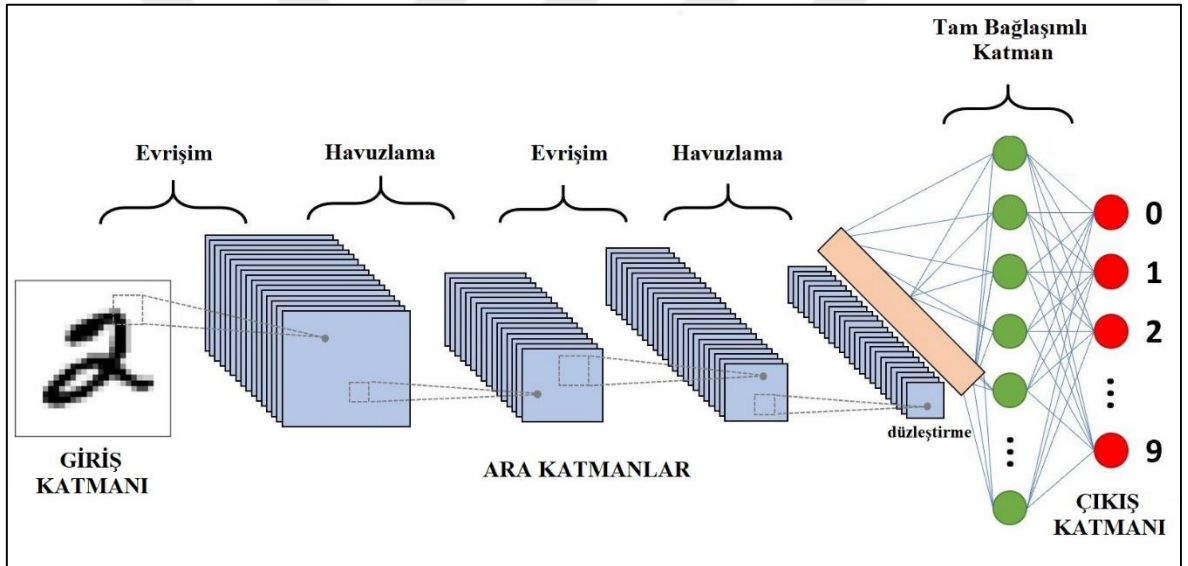
Şekil 2.9. Veri çoğaltma işlemi sonucu veri setindeki bir görüntüden elde edilen çıktılara örnekler.

a) orijinal, b) çevirme, c) rotasyon, d) parlaklık değişimi, e) bulanıklaştırma, f) kontrast değişimi.

2.4. Derin Öğrenme

İnsan beyninin yapısı ve fonksiyonundan ilham alan derin öğrenme, günümüzün en popüler konuları arasındadır. Çok katmanlı yapay sinir ağı olarak lanse edilen derin öğrenme algoritmaları; görüntü, ses ve metin başta olmak üzere pek çok farklı sektörde uygulama alanı bulabilmektedir. Derin öğrenme algoritmaları tarafından insanların yüzlerini [49], parmak izlerini [50], el yazılarını [51], duygularını [52] tespit edebilmek; savunma teknolojisinde gemileri tasnifleyebilmek [53], nesne tespit edebilmek [54]; biyomedikal alanında hastalık tespiti yapabilmek [55] mümkündür.

Klasik bir derin öğrenme modeli, giriş katmanı, ara katman ve çıkış katmanından oluşur. Modeldeki ara katman yapısı, yapay sinir ağlarına kıyasla oldukça fazla sayıda ve karmaşık yapıdadır. Klasik bir derin öğrenme modeli Şekil 2.10'da verilmiştir.

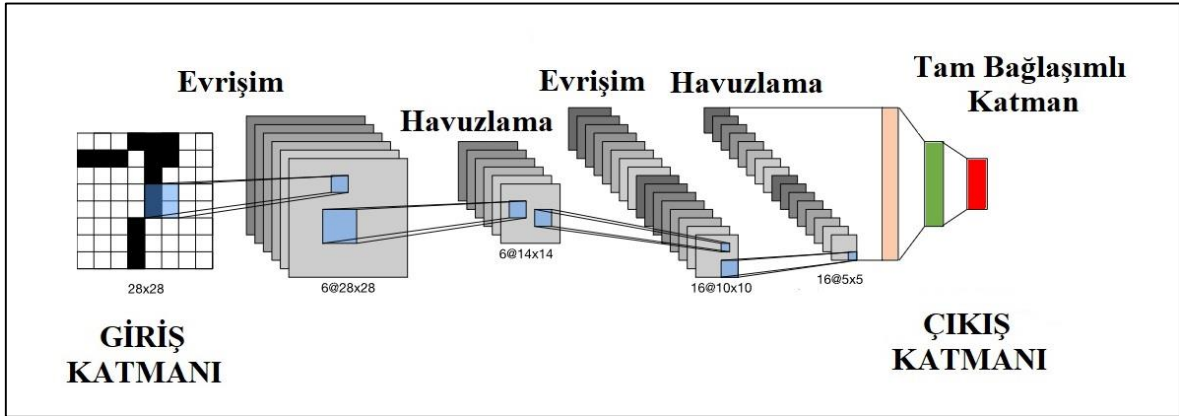


Şekil 2.10. Klasik bir derin öğrenme modeli katmanları [56].

Özellikle görüntü işleme alanında en çok tercih edilen derin öğrenme algoritmalarından biri Evrişimsel Sinir Ağları'dır. Bu ağlarda kullanılan evrişim katmanları, veriden çıkarılan özniteliklerin daha ayırt edici olmasını sağlamaktadır. Bu ağlar, girdi verilerindeki anlamlı örüntüleri bularak nesne tespiti ve takibi, görüntü sınıflandırması, biyomedikal görüntü analizi gibi pek çok farklı disiplinde kullanılabilir.

İlk CNN mimarisi, 1989 yılında Lecun ve ekibi tarafından LeNet adıyla meydana getirilmiştir [57]. El yazısı rakamlarını okumak amacıyla geliştirdikleri 7 katmanlı ağ

modeli, görüntü işleme alanında önemli bir başarı elde etmiştir. LeNet mimarisi Şekil 2.11’de gösterilmiştir.



Şekil 2.11. LeNet mimarisi [57].

Basit bir CNN modeli aşağıdaki ana katmanlardan oluşur.

a) Evrişim Katmanı (Konvolüsyon Katmanı): Veriye uygun olarak belirlenmiş bir filtrenin, girdi görüntüsünün pikselleri üzerinde teker teker kaydırılması işlemidir. Kaydırma sırasında filtredeki değerler görüntünün orijinal piksel değerleri ile çarpılarak toplanır ve tek değer olarak yazılır. Bu işlem, tüm girdi görüntüsü boyunca devam ettirilir. Evrişim katmanı; girdi görüntülerindeki öznitelikleri çıkarmaya yarayan en önemli araçlardan biridir. A girdi matrisi, h ise kernel (çekirdek) matrisi olmak üzere; iki boyutlu bir evrişim işlemi, (2.2)’deki gibi hesaplanır.

$$g(x, y) = A * h = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} h(i, j) \times A(x - i, y - j) \quad (2.2)$$

Matematiksel formülün kullanıma örnek olması adına, değer atanmış iki matrisin detaylı bir evrişim işlemi aşağıda gösterilmiştir.

$$A = \begin{bmatrix} 50 & 75 & 77 \\ 48 & 70 & 83 \\ 51 & 68 & 85 \end{bmatrix} \quad h = \begin{bmatrix} -1 & -1 & -1 \\ -2 & 10 & -2 \\ -1 & -1 & -1 \end{bmatrix}$$

A matrisinin 2. Satır 2. Sütun elementi olan 70 elemanının evrişim sonucundaki değeri incelenirse;

$$g(x,y) = h(-1,-1) A(x+1,y+1) + h(0,-1) A(x,y+1) + h(1,-1) A(x-1,y+1) + h(-1,0) A(x+1,y) + h(0,0) A(x,y) + h(1,0) A(x-1,y) + h(-1,1) A(x+1,y-1) + h(0,1) A(x,y-1) + h(1,1) A(x-1,y-1) \quad (2.3)$$

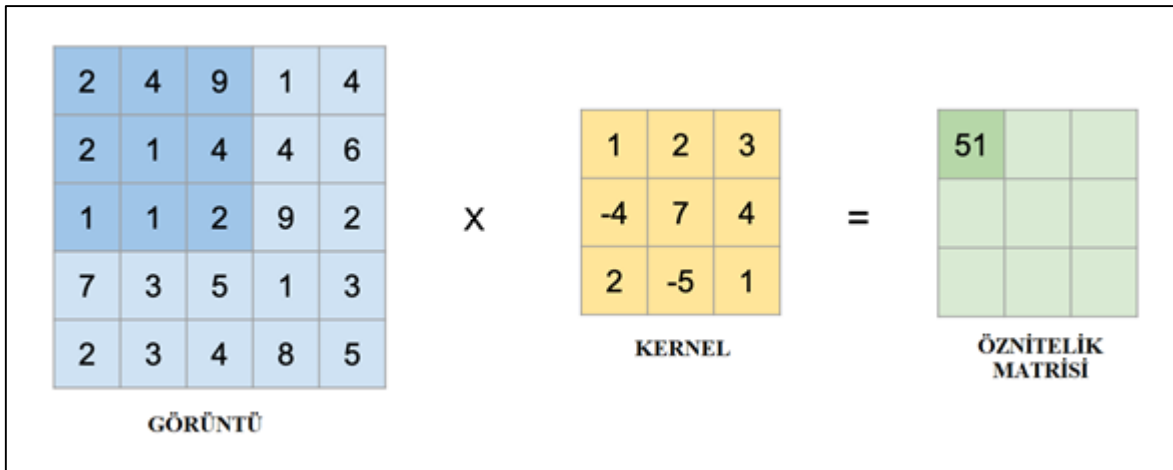
(2.3) formülü uygulanarak,

$$g(x,y) = (-1 \times 85) + (-1 \times 68) + (-1 \times 51) + (-2 \times 83) + (10 \times 70) + (-2 \times 48) + (-1 \times 77) + (-1 \times 75) + (-1 \times 50) = -85 - 68 - 51 - 166 + 700 - 96 - 77 - 75 - 50 = \mathbf{32} \quad (2.4)$$

(2.4)'te hesaplanan 32 değeri elde edilir. Yani girdi matrisinin 70 olan değeri, evrişim işlemi sonucunda 32 olarak bulunmuştur [58].

Başka bir girdi görüntü matrisi üzerinde ise yapılan tüm evrişim işlemleri ise adım adım aşağıda görselleştirilerek anlatılmıştır (Şekil 2.12-2.15). Bu işlemler sırasında filtrenin kayma adımı (stride size) 1 olarak seçilmiştir. Bu değer farklı seçilmesi durumunda, veriden farklı öznitelikler elde edilebilir. Eğer girdi, RGB gibi 3 kanala sahip ise, aynı işlemler tüm kanallar üzerinde yapılır [59].

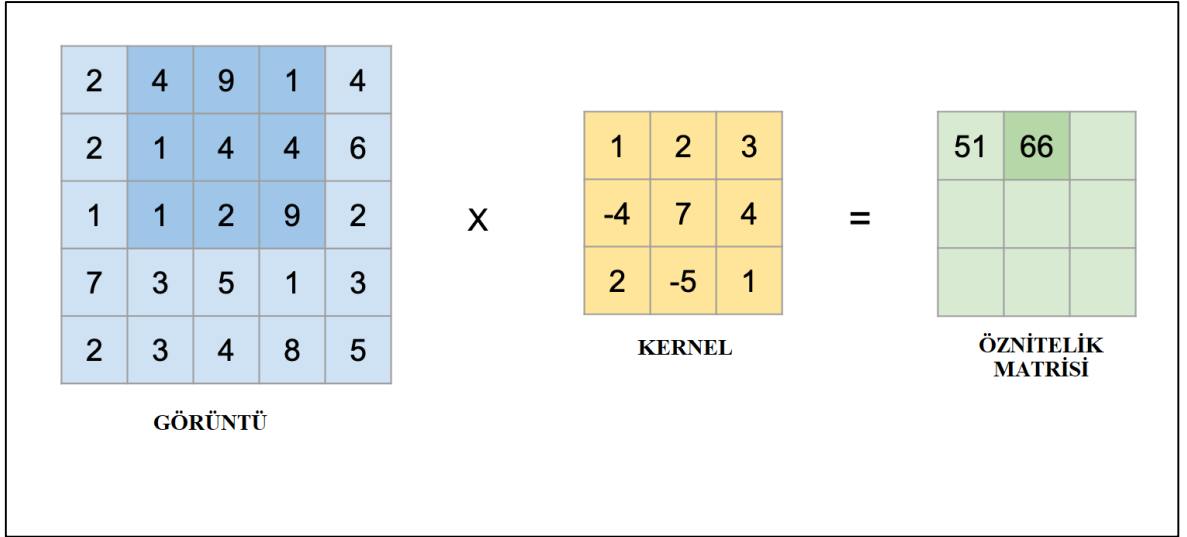
Şekil 2.12'de, görüntü matrisi ile kernel matrisi arasında yapılan ilk matematiksel işlem (2.5)'teki gibidir.



Şekil 2.12. Evrişim işlemi.

$$2 \times 1 + 4 \times 2 + 9 \times 3 + 2 \times (-4) + 1 \times 7 + 4 \times 4 + 1 \times 2 + 1 \times (-5) + 2 \times 1 = \mathbf{51} \quad (2.5)$$

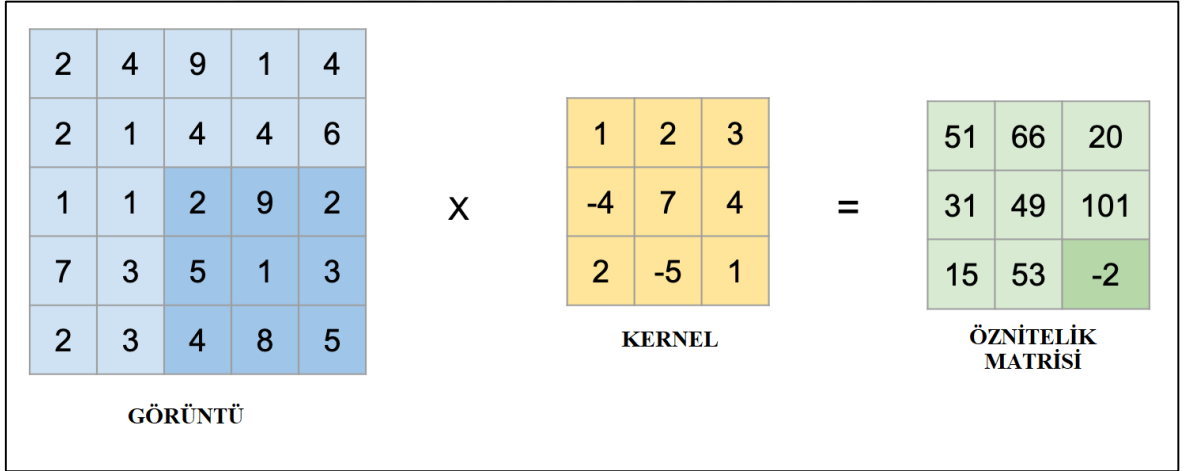
Kernel, Şekil 2.13'te bir adım sağa kaydırılarak ikinci 3x3 boyutlu alt matrisle (2.6)'daki gibi işleme alınmış, 66 değeri elde edilmiştir.



Şekil 2.13. Evrişim işlemi devamı.

$$4x1 + 9x2 + 1x3 + 1x(-4) + 4x7 + 4x4 + 1x2 + 2x(-5) + 9x1 = 66 \quad (2.6)$$

Kernel, tüm girdi görüntü matrisi üzerinde gezdirilmeye devam ederse son adımda öznitelik matrisindeki son piksel değeri (2.7)'deki gibi hesaplanır.



Şekil 2.14. Evrişim işlemi sonucu.

$$2x1 + 9x2 + 2x3 + 5x(-4) + 1x7 + 3x4 + 4x2 + 8x(-5) + 5x1 = -2 \quad (2.7)$$

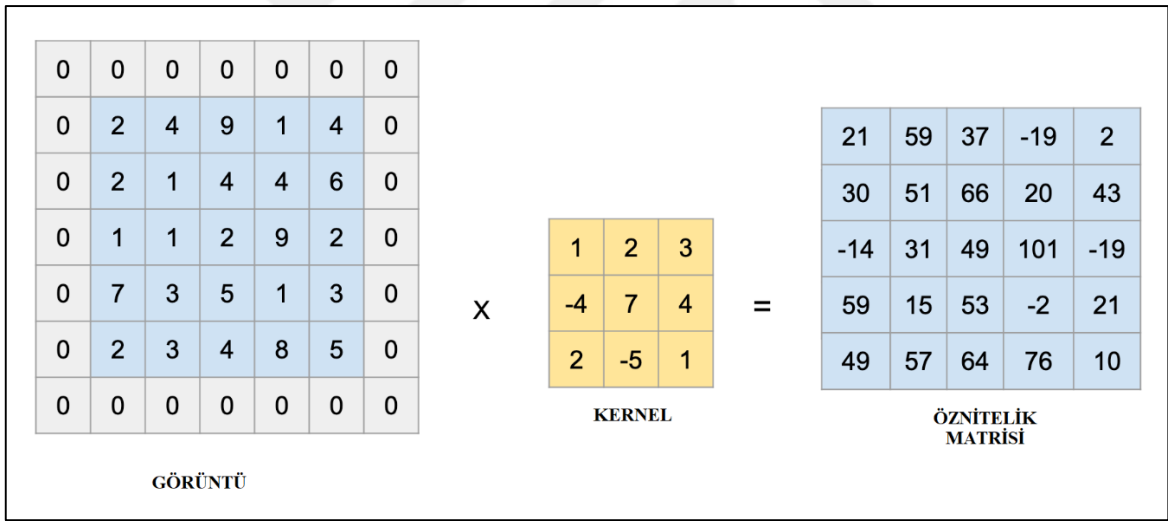
Öznitelik matrisinin boyutu, girdi görüntüsü ile kernelin boyutuna göre öncesinde (2.8) kullanılarak hesaplanabilir [59].

$$\text{Öznitelik matris boyutu} = \frac{\text{Görüntü matrisi boyutu} - \text{Kernel matrisi boyutu}}{\text{Kayma Miktarı}} + 1 \quad (2.8)$$

Bu formül, evrişim işlemini doğrulamak adına yukarıdaki örnek matrislere (2.9)'daki gibi uygulanır.

$$\text{Öznitelik matris boyutu} = \frac{5-3}{1} + 1 = 3 \quad (2.9)$$

(2.9)'da elde edilen sonuç, işlemi doğrular niteliktedir. Çıktı ve formül incelendiğinde; öznitelik matris boyutunun, girdi görüntüsüne oranla daha küçük olduğu göze çarpmaktadır. Fakat bazı durumlarda giriş ile öznitelik matrisinin aynı boyutta olması istenebilir. Bu durumda görüntü matrisine, dolgulama (padding) adı verilen bir işlem yapılır. En basit haliyle dolgulama işlemi, girdi matrisinin etrafına sıfırlar ekleyerek görüntü boyutunu artırmaktır. Bu sayede, girdi matrisinin sınırlarında kaybolan veriler de öznitelik matrisine dahil edilebilmektedir. Örnek teşkil etmesi adına Şekil 2.15'te verilen 5x5 boyutundaki bir girdi matrisi etrafına 0 değerleri yerleştirilerek, boyutu 7x7'ye çıkarılmıştır. Dolgulanmış matris, 3x3 boyutundaki kernel ile evrişim yapıldığında, öznitelik matrisi 5x5 olarak elde edilmektedir [59].



Şekil 2.15. Dolgulama ile evrişim işlemi.

Dolgulama işlemi söz konusu olduğunda, öznitelik matrisinin boyutu, (2.10) uygulanarak hesaplanır [59].

$$\text{Öznitelik matris boyutu} = \frac{\text{Görüntü matrisi boyutu} + 2 \times \text{Dolgulama boyutu} - \text{Kernel matrisi boyutu}}{\text{Kayma Miktarı}} + 1 \quad (2.10)$$

Doğrulamak adına, yukarıdaki örnek matrislere formül uygulanırsa; (2.11)'de verilen hesaplama neticesinde, 5x5 boyutunda bir öznitelik matrisi elde edileceği görülür. Yine elde edilen sonuç, yapılan işlemi doğrular niteliktedir.

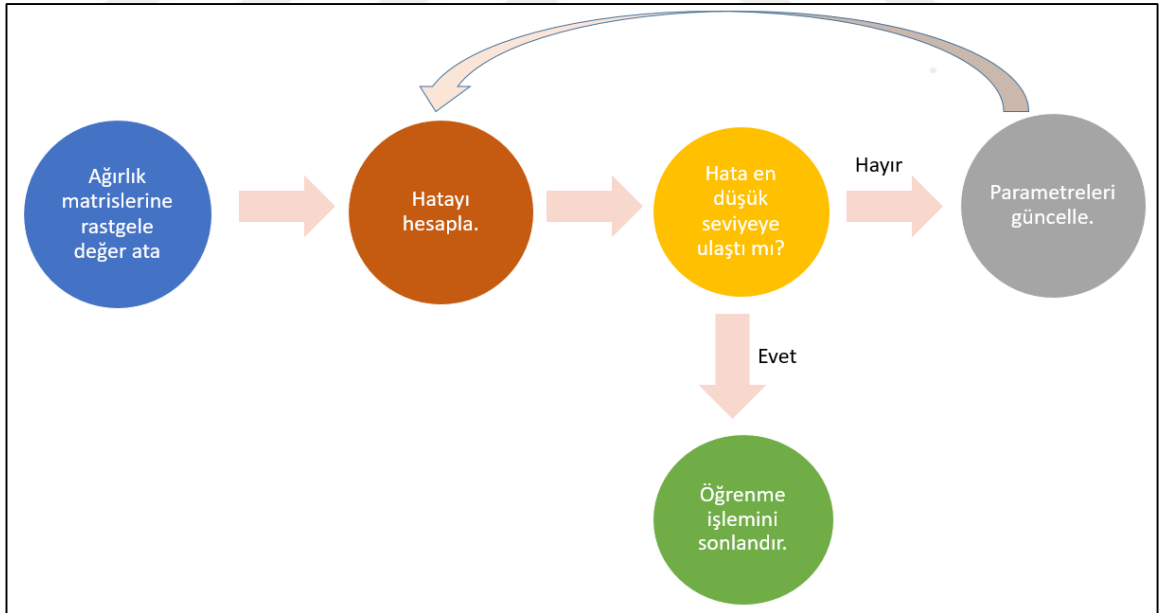
$$\text{Öznitelik matris boyutu} = \frac{5+2 \times 1-3}{1} + 1 = 5 \quad (2.11)$$

Derin ağlarda en sık kullanılan katman olan evrişim katmanında, uygulanacak kernelin ne olacağı, ağ tarafından geri yayılım (back propogation) algoritması sayesinde öğrenilir. Geri yayılım algoritması, delta kuralı olarak da isimlendirilir. Bu algoritma, hata fonksiyonunun minimum değerini arayarak ağdaki öğrenme işini üstlenir.

Bu algoritmaya ait işlemsel adımlar:

- İlk olarak ağırlık vektörlerine (w) rastgele değer ataması yapılır.
- Atanan değerler ile bir hata hesaplaması yapılır.
- Hesaplanan hata değerini azaltmak için w değerleri güncellenir.
- Güncellenen w vektörleri ile tekrar hata hesaplanır.

Bu işlem, belli bir iterasyon sayısı ya da ağdan hedeflenen minimum hata payı elde edilinceye kadar devam eder. Algoritma adımları Şekil 2.16’da gösterilmiştir.




Şekil 2.16. Geri yayılım algoritması adımları.

b) Havuzlama (Ortaklama): Bu katmanda genellikle maksimum havuzlama (max. pooling) yöntemi kullanılır. Bu katman sayesinde girdi boyutları küçültülerek hesaplama

maliyeti düşürülür. Yine yukarıdaki örnek matrisler üzerinden yapılan maksimum havuzlama işlemleri görseller yardımıyla adım adım incelenmiştir (Şekil 2.17-2.19).

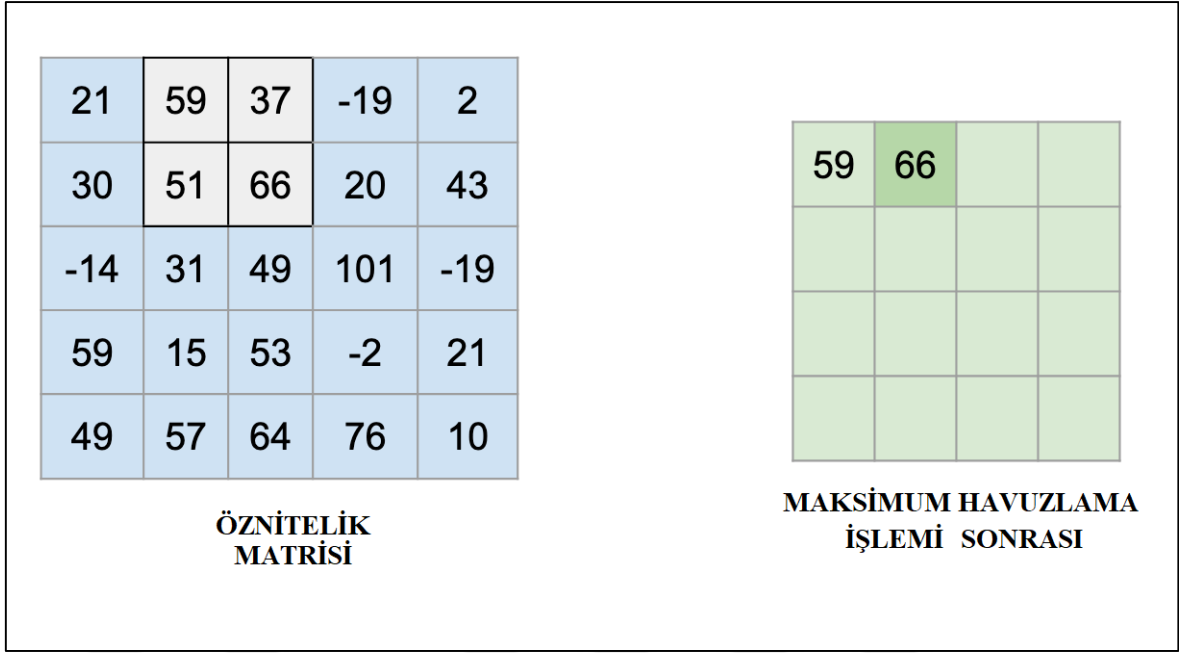
Şekil 2.17’de, evrişim sonrası elde edilen öznitelik matrisine ait ilk 2x2’lik alt matris eleman değerlerine bakıldığında; aralarında en büyük değere sahip olanın 59 değerlikteki piksel olduğu görülür. 59 değeri alınarak, 2x2’lik alt matris elemanları yerine çıktıda tek değer olarak yazılır.




Şekil 2.17. Havuzlama işlemi.

Benzer şekilde, evrişim sonrası elde edilen öznitelik matrisinin ikinci 2x2’lik alt matris değerlerine bakılır ve bunlar içerisinde en yüksek değere sahip olan 66 piksel değeri alınır (Şekil 2.18). Bu şekilde tüm alt matris değerleri incelendiğinde, elde edilen matris Şekil 2.19’da verilen şekilde olur.

Maksimum havuzlama dışında, ortalama havuzlama (average pooling) adı verilen bir yöntem daha mevcuttur. Bu yöntemde de evrişim sonrası elde edilen matris içerisinde, maksimumu yerine ortalama değerleri alınır. Ancak maksimum havuzlama yöntemi, gürültülü verinin sonraki katmanlara aktarımını engelleyerek gürültünün azaltılmasına yardımcı olması nedeniyle daha çok tercih edilir [59].



Şekil 2.18. Havuzlama işlemi devamı.



Şekil 2.19. Havuzlama işlemi sonucu.

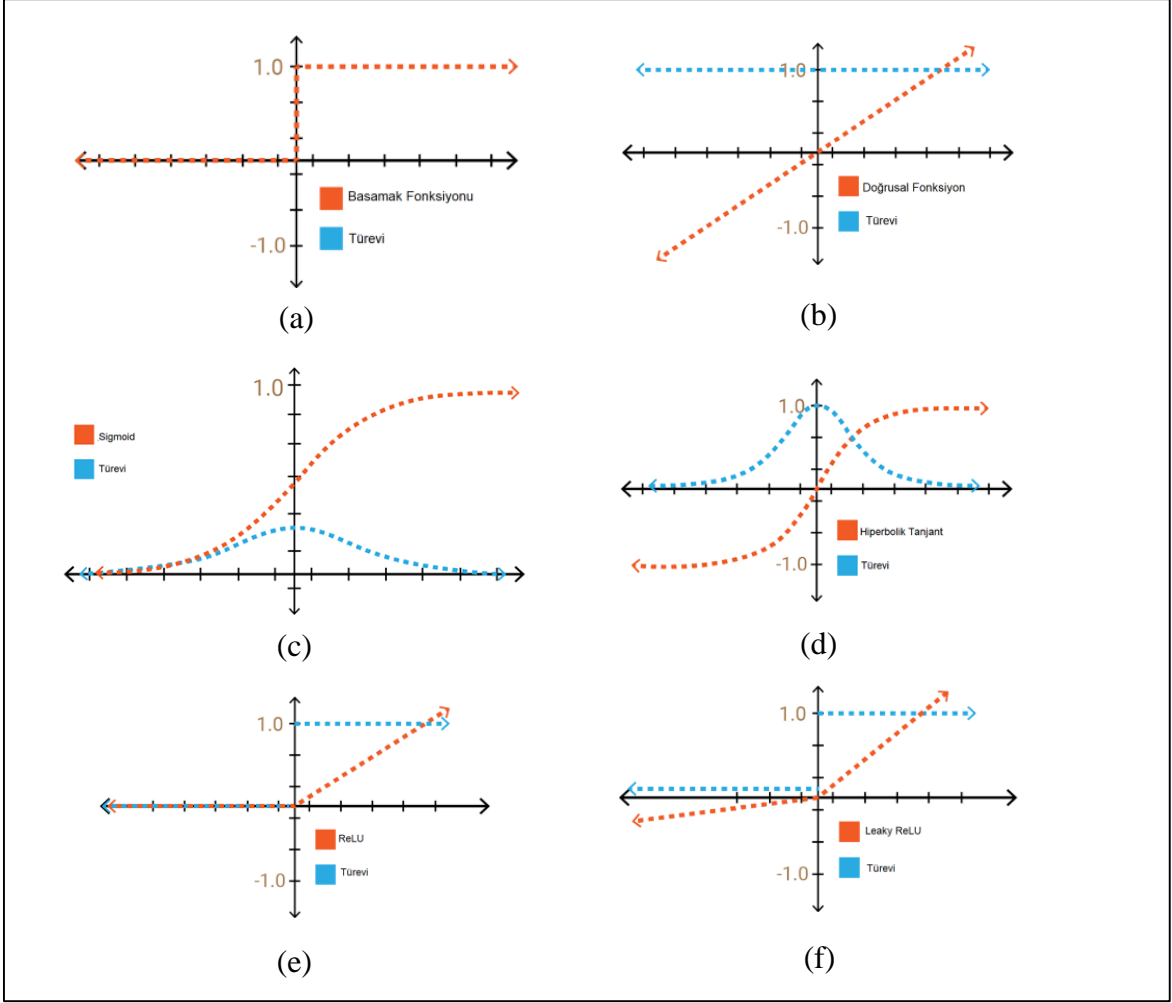
Evrişim ve havuzlama katmanları, ağ içerisinde istenildiği kadar kullanılabilir. Her bir katman sonrası daha yüksek öznitelik uzayına geçilir ve en nihayetinde elde edilen özniteliklerin sınıflandırılması yapılır. Burada kaç katman kullanılacağı, filtrenin hangi boyutta seçileceği, evrişim aşamasında filtrenin kaç adımda bir kayacağı gibi parametrelerin seçimi, kullanılan veri setine ve uygulama amacına bağlı olarak değişmektedir.

Bunun yanı sıra, elde edilen veriler doğrusal olmayan içerikte olduğundan dolayı bir aktivasyon fonksiyonundan geçirilirler. Aktivasyon fonksiyonunun kullanılmaması durumunda, çıkış verisi basit bir doğrusal fonksiyona indirgenir ve öğrenme işlemi tam anlamıyla gerçekleştirilemez. Dolayısıyla türevlenebilir fonksiyonlar, bu anlamda oldukça önemli nitelik taşımaktadırlar [60].

Birçok farklı aktivasyon fonksiyonu yer almasına karşın; derin öğrenme mimarilerinde genellikle düzeltilmiş doğrusal birim (Rectified Linear Unit, ReLU) fonksiyonu tercih edilir. Çünkü bu fonksiyon, diğer aktivasyon fonksiyonlarına oranla oldukça hızlı sonuç üretir. Bu fonksiyon genellikle evrişim havuzlama katmanları sonrasında kullanılır. Bu fonksiyonun haricinde basamak (step), doğrusal (linear), sigmoid, hiperbolik tanjant (tanh), sızıntı ReLU (Leaky ReLU) gibi fonksiyonlara rastlamak da mümkündür. Fonksiyonlar ve türevleri Şekil 2.20’de karşılaştırılmalı olarak verilmiştir.

Her aktivasyon fonksiyonu, kendine özgü avantaj ve dezavantajlara sahiptir. Birim basamak fonksiyonu, sadece 0 ve 1 değerlerini alabildiği için ikili sınıflandırmalarda kullanılır. Bu sebeple de gizli katmanlardan ziyade ağların çıkış katmanlarında tercih edilir. Benzer şekilde; doğrusal fonksiyonun türevi de sabit bir değer olduğu için giriş ile çıkış arasında yer alan ara katmanlar önemini yitirdiğinden, bu fonksiyon da derin ağlarda tercih edilmez [60].

Sigmoid fonksiyonu YSA’da en sık kullanılan aktivasyon fonksiyonudur. Çünkü bu fonksiyon, her bölgede türevlenebilir ve sonucunda da öğrenme işlemi gerçekleştirilebilir. Ancak bu fonksiyon çok yavaş çalışır ve derin katmanlı mimarilerde pek tercih edilmez. Bunun yanı sıra, fonksiyonun bazı bölgelerinde x eksenindeki değişiklikler, y eksenine fazla yansıyamaz ve türevlerinin sıfıra yakınsaması problemini beraberinde getirir [60]. Bu problem literatürde “kaybolan gradyan” ya da “ölü gradyan (vanishing gradient)” problemi olarak geçer ve öğrenme işleminin durduğuna işaret eder.




Şekil 2.20. Sinir ağlarında kullanılan aktivasyon fonksiyonları ve türevleri. a) basamak fonksiyonu, b) doğrusal fonksiyon, c) sigmoid fonksiyonu, d) tanh fonksiyonu, e) ReLU fonksiyonu ve f) sızıntılı ReLU fonksiyonu [60].

Sigmoid fonksiyonuna benzer yapıda olan tanh ise, -1 ile +1 arasında değer almaktadır. Sigmoid fonksiyonuna göre avantajı, türevinin daha dik olması; böylece daha hızlı çalışması olarak gösterilebilir. Ancak sigmoid fonksiyonunda olduğu gibi, tanh fonksiyonunda da kaybolan gradyan problemiyle karşılaşılabilir [60].

ReLU, bahsedildiği gibi hızlı sonuç vermesine karşın; sıfır değer bölgesinin türevinin de sıfır olmasından kaynaklı bu bölgede ölü gradyanlara sahiptir ve bu nedenle öğrenme işlemini tam gerçekleştiremez. Bu sorunu engellemek için sızıntılı ReLU fonksiyonu önerilebilir; ancak algoritma hızının önemli olduğu bir problemde bu fonksiyon da ReLU kadar hızlı çalışmaz. Neticede tüm bu anlatılanlar, ReLU fonksiyonunun çok katmanlı derin ağ mimarileri için daha uygun olduğuna işaret etmektedir.


c) Tam Baęlaşımli Katman: Bu katman, sınıflandırmadan önceki son katman olarak kullanılır ve girdi, sınıf sayısı boyutunda bir vektör haline getirilir. Bu katmanda konumlandırılmış bir softmax (yumuşatma) fonksiyonu ile çıkarılan yüksek seviyeli öznitelikler bir sınıf ile baędaştırılır. Tam baęlaşımli katman Şekil 2.21’de resmedilmiştir.



Şekil 2.21. Tam baęlaşımli katman.

Derin aę mimarilerinde genellikle iki ardışık tam baęlaşımli katmanlar arasında, ezberleme probleminin önüne geçilmesi maksadıyla aktivasyon fonksiyonu ve bırakma katmanı (seyreltme katmanı, dropout layer) kullanılır. Son tam baęlaşımli katman ise tüm aęın çıktısına göre şekillenir. Uygulamadaki sınıf sayısı, son kattaki tam baęlaşımli katmanın boyutuna karar verir. Bu katmanda, sınıf sayısı kadar düęüm (node) olur ve her düęüm için (0-1) arasında bir olasılık deęeri atanır. En yüksek olasılık deęerine sahip olan düęüm hangi sınıfı niteliyor ise, aęın çıktısı o sınıf olarak verilir.

Seyreltme katmanı, sinir aęlarına ezberlemeyi azaltmak için kullanılan bir teknik olarak geçer. Seyreltme işlemleri, giriş tensörünün bazı baęlantılarının rastgele atılmasıyla gerçekleştirilir. İşlem, Şekil 2.22’de gösterilmiştir. Şekildeki kırmızı baęlantılar sıfırlanarak yok edilmiştir [59].



Şekil 2.22. Seyreltme (bırakma) işlemi.

2.4.1. Sıfırdan Öğrenme (Learn from Scratch)


Geleneksel makine öğrenmesinde, farklı görevler için farklı modeller sıfırdan öğrenilerek (learn from scratch) geliştirilir. Eğitim işlemi için sadece hedef alana hizmet eden veriler kullanılır [61]. Bu yöntemde, öğrenme işleminin iyi gerçekleşebilmesi adına geniş ölçekli bir veri kümesine gereksinim duyulur.

Ancak özellikle öğrenme işleminin çok uzun zaman sürdüğü ve donanımsal ihtiyacın fazla olduğu derin öğrenme modellerini meydana getirirken; bazı görevlerden edinilen bilgiler, farklı görevlerde de kullanılabilmekte, zaman ve maliyet açısından fayda sağlamaktadır. Bu yöntem öğrenme aktarımı olarak isimlendirilir.

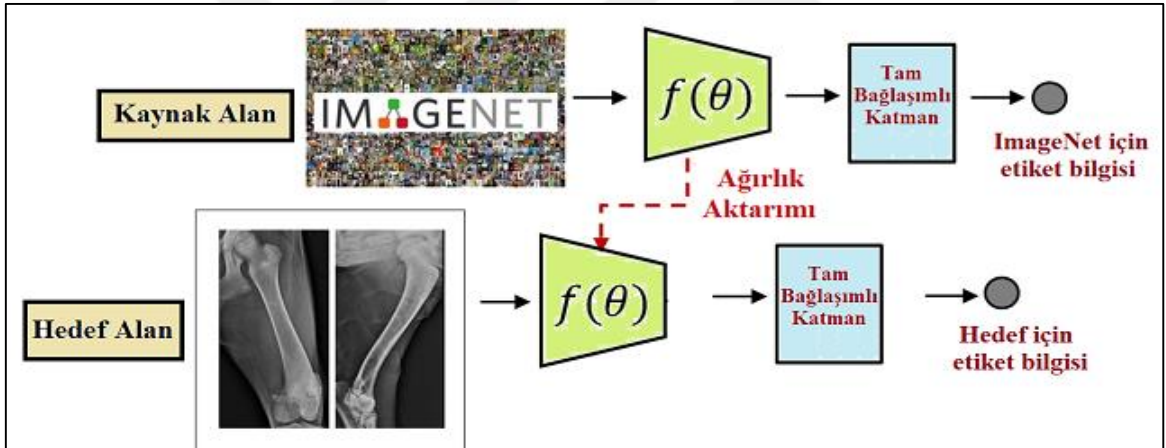
2.4.2. Öğrenme Aktarımı (Transfer Learning)

Öğrenme aktarımı, derin öğrenme mimarilerinin bir problemi çözerken elde ettiği bilgiyi saklayıp karşılaşmadığı bir problem çözümünde o bilgiyi kullanması olarak tanımlanabilir. Bilgi transferi, kaynak modellerin elde ettiği özellik ve ağırlıkların yeni görevlere aktarılması ile olur.

Sıfırdan öğrenme ve öğrenme aktarımı yöntemlerinin görsel anlatımları Şekil 2.23, 2.24 ve 2.25'te sunulmuştur. Şekil 2.24 ile 2.25'te gösterildiği gibi; öğrenme aktarımında sınıflandırma işlemi iki farklı metot ile gerçekleştirilebilir [61]. Bunlardan ilki, derin öğrenme modellerinin son katmanını oluşturan tam bağlaşımlı katman çıktısını kullanarak etiket bilgisine ulaşmaktır. Diğerisi ise destek vektör makineleri gibi geleneksel makine öğrenmesinde kullanılan sınıflandırıcılar sayesinde etiket bilgisini elde etmektir.

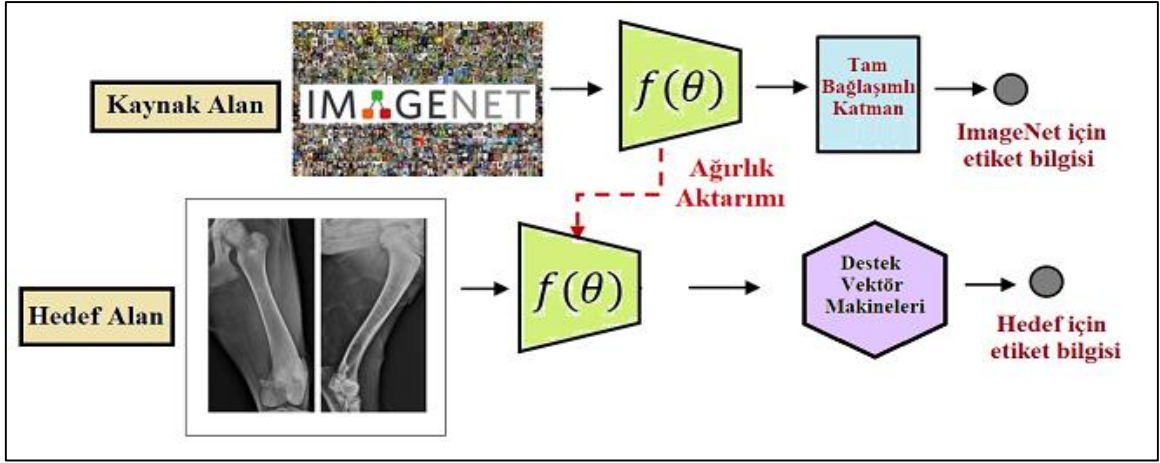


Şekil 2.23. Sıfırdan öğrenme.



Şekil 2.24. Öğrenme aktarımı (sınıflandırma işlemi tam bağlaşımlı katman ile yapılmıştır).

Öğrenme aktarımı işlemi, her zaman başarılı sonuçlar meydana getirmeyebilir. Kaynak ile hedef arasındaki veri seti ve/veya amaç farklılığı, aktarım işleminin performansını doğrudan etkiler. Bu etki olumlu sonuçlanabileceği gibi olumsuz da sonuçlanabilir. Bu sebeplerle öğrenme aktarımı yaparken kaynak modeldeki hangi bilgilerin hedef modele nasıl aktarılacağına doğru karar vermek gerekir [62].



Şekil 2.25. Öğrenme aktarımı (sınıflandırma işlemi destek vektör makineleri ile yapılmıştır).

Öğrenme aktarımı tekniği, uygulamalarında dikkat gerektirse de önemli avantajlara sahiptir. Bu avantajlardan en önemlisi, önceden eğitilmiş modellerin ağırlık katsayılarını barındırması sayesinde eğitim süresini oldukça az zamanda gerçekleştirebilmesidir. Ayrıca sıfırdan öğrenen modellerin gereksinim duyduğu büyük çaptaki veri kümesi yerine öğrenme aktarımı sayesinde ince ayarlar (fine tuning) yapılarak daha az veri ile daha başarılı çıktılar almak mümkündür.

Günümüzde büyük veri kümeleri ile eğitilmiş, iyi genelleme yapabilen, kullanıma hazır pek çok model bulunmaktadır. Bunların başında AlexNet, Inception, VGGNet, ResNet modelleri gelmekte olup halihazırda bu modellerden türetilmiş pek çok sürüm de mevcuttur. Var olan modellerin elde ettiği bilgiler, hedef modele doğrudan veya çeşitli modifikasyonlarla uygulanabilir [62].

Öğrenme aktarımı yöntemi kaynak model ile hedef model amaç/görevlerine göre tümevarımsal, dönüştürücü ve gözetimsiz öğrenme aktarımı olacak şekilde üç sınıfta incelenebilirken; kaynak ile hedef alan arasında ne transfer edileceğine göre ise örnek, özellik, parametre ve ilişki kurma tecrübesi aktarımı olarak dört sınıfta incelenebilir [62].

2.4.3. Tümevarımsal Öğrenme Aktarımı (Inductive Transfer Learning)

Kaynak ile hedef alan arasında amaç/görev farklılığı söz konusudur. Kaynak modelleri meydana getirirken kullanılan veriler etiketli ise, öğrenme aktarımı çok yönlü (multi-task learning) olur. Bu tip çok yönlü öğrenmelerde kaynak model, hedef modellerin temelini

oluşturur [62]. El yazısı rakamlarını sınıflandırma için yaratılan bir modelin, araç cinsini sınıflandırmada kullanılması çok yönlü öğrenme aktarıma örnek olarak verilebilir.

Kaynak modelleri meydana getirirken kullanılan veri etiket bilgisi içermiyor ise öğrenme aktarımı kendi kendine (self taught learning) olur. Bu tip kendi kendine öğrenmelerde kaynak model bilgileri doğrudan kullanılamaz ve fazla tercih edilmez. Ne olduğuna dair herhangi bir bilgi içermeyen görüntüler ile oluşturulan bir modelin, araç cinsini sınıflandırmada kullanılması kendi kendine öğrenme aktarıma örnek olarak verilebilir [62].

2.4.4. Dönüştürücü Öğrenme Aktarımı (Transductive Transfer Learning)

Kaynak ile hedef alan arasındaki amaç/görev aynı iken; kullanılan verilerin farklı olması durumudur. Bu tip öğrenme, hedef görevde yeterince etiketli verinin olmadığı durumlarda elverişlidir. Çünkü kaynak model, büyük veri setleri kullanılarak oluşturulmuştur [62].

2.4.5. Gözetimsiz Öğrenme Aktarımı (Unsupervised Transfer Learning)

Tümevarımsal öğrenmeden farkı, etiket bilgisi kullanılmayan görevlerde tercih edilmesidir. Kaynak model ile hedef modellerde kullanılan veri setleri benzer olup, amaçları birbirinden farklıdır. Bu tip öğrenme aktarımları daha çok kümeleme işlemlerinde kullanılır [62].

2.4.6. Örnek Aktarımı (Instance Transfer)

Kaynak modelde uygun ağırlık katsayısı atanmış bazı örneklerin hedef modelde de uygulanmasıdır. Kaynak veriler ile hedef verilerin benzemesi durumunda tercih edilen yöntemdir [62]. Bu tip öğrenmeye el yazısı rakamlarını sınıflandıran bir modelin el yazısı harflerini sınıflandırması örnek olarak verilebilir.

2.4.7. Öznitelik Temsili Aktarımı (Feature Representation Transfer)

Kaynak modelden elde edilen özniteliklerin hedef modelde kullanılmasıdır. Kaynak veriler ile hedef verilerin benzemesi durumunda tercih edilen yöntemdir [62]. Bu tip öğrenmeye yüz tanıma modelinin göz ve dudak çevresi ile ilgili çıkardığı öznitelikleri kullanarak insan yaşı tespiti yapan bir model örnek olarak verilebilir.

2.4.8. Parametre Aktarımı (Parameter Transfer)

Kaynak modelden hedefe parametre aktarımı yapılır. Kaynak ve hedef görevlerinin benzemesi durumunda tercih edilen yöntemdir [62].

2.4.9. İlişki Kurma Tecrübesi Aktarımı (Relational Knowledge Transfer)


Kaynak ile hedef arasında ilişki kurularak, ilişkili bilgilerin hedef modele aktarılmasıdır [62].

2.5. Derin Öğrenme Modelleri

2.5.1. AlexNet

2012 yılında G. Hinton ve Alex Krizhevsky, günümüzde AlexNet olarak bilinen derin ağ mimarisini literatüre kazandırmış, sekiz katmanlı bir evrişimsel sinir ağını eğitmiştir [63].

2012 yılında gerçekleştirilen ILSVRC ImageNet yarışmasını kazanan bu model, derin öğrenme için bir dönüm noktası olmuştur. Model, 5'i evrişim ve 3'ü tam bağlaşımlı olmak üzere toplamda 8 katmandan oluşmaktadır. Mimariide kullanılan filtreler 11x11 boyutlarında seçilmiştir. Ayrıca model, ReLU fonksiyonunu aktivasyon fonksiyonu olarak kullanan ilk derin ağ modelidir. Model, yaklaşık 60 milyon parametreye sahiptir. Mimari yapı, Şekil 2.26'daki gibidir.

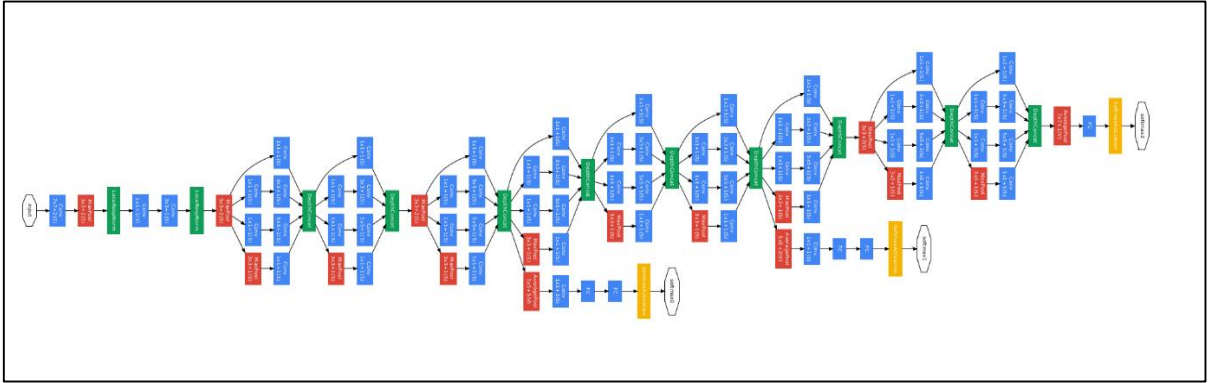


Şekil 2.26. AlexNet mimarisi [63].

2.5.2. GoogleNet (Inception-v1)

2014 yılında sunulan bu model, o yıl düzenlenen ImageNet yarışmasını kazanan derin ağ modeli olmuştur. Toplamda 22 katmandan oluşan model, AlexNet'e oranla daha derin bir yapıya sahiptir. Bu modelde, paralel modüller kullanılarak ezberleme (overfitting)

probleminin önüne geçilmeye çalışılmıştır [64]. GoogLeNet mimari yapısı Şekil 2.27’de verilmiştir.



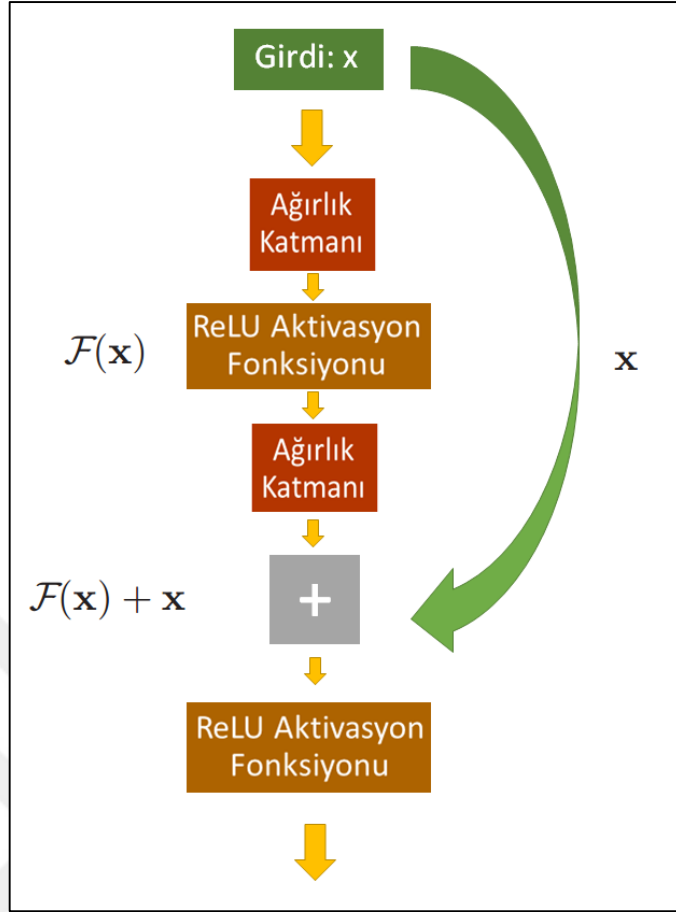
Şekil 2.27. GoogLeNet mimarisi [64].

2.5.3. ResNet

2015 yılında ResNet, bir önceki yıl GoogLeNet’in yakaladığı %6,67’lik hata payını, %3,57’ye düşürerek birinci seçilmiştir. Bu derin ağ modelinde, artık blok (residual block) olarak geçen yeni bir yapı eklenerek farklı bir yaklaşım uygulanmıştır. Bu yaklaşıma göre, iki katman arasındaki bazı katmanlar atlanarak; girdi doğrudan ağın çıkışına eklenir ve kısa yol bağlantıları oluşturulur [65]. Artık katmanı ifade eden yapı, Şekil 2.28’de verilmiştir. Şekilden de anlaşılacağı gibi, x blok girdisi olmak üzere, blok çıkışı $(F(x) + x)$ ’e eşit olacaktır. Buradaki $F(x)$, x giriş verisinin ağırlık katman çıkışını ifade etmektedir.

Artık blok yapısı, kaybolan gradyan sorununa çözüm getirmek amacıyla ortaya atılmıştır. Bu sorun, eğitim sırasında hata sinyalinin çok küçük değerler alması sebebiyle ağırlıkların güncellenememesi ve beraberinde eğitim işleminin sonlanması anlamına gelir. Teori ağ içerisindeki katman sayısı artırıldıkça eğitim hatasının azalması yönündedir; ancak pratikte ağa daha fazla katman eklemek, eğitim hatasının kaybolan gradyan sebebiyle artmasına neden olur. ResNet’in artık blokları sayesinde, ağı daha derin yaparak eğitim hatasını azaltmanın yolu bulunmuştur.

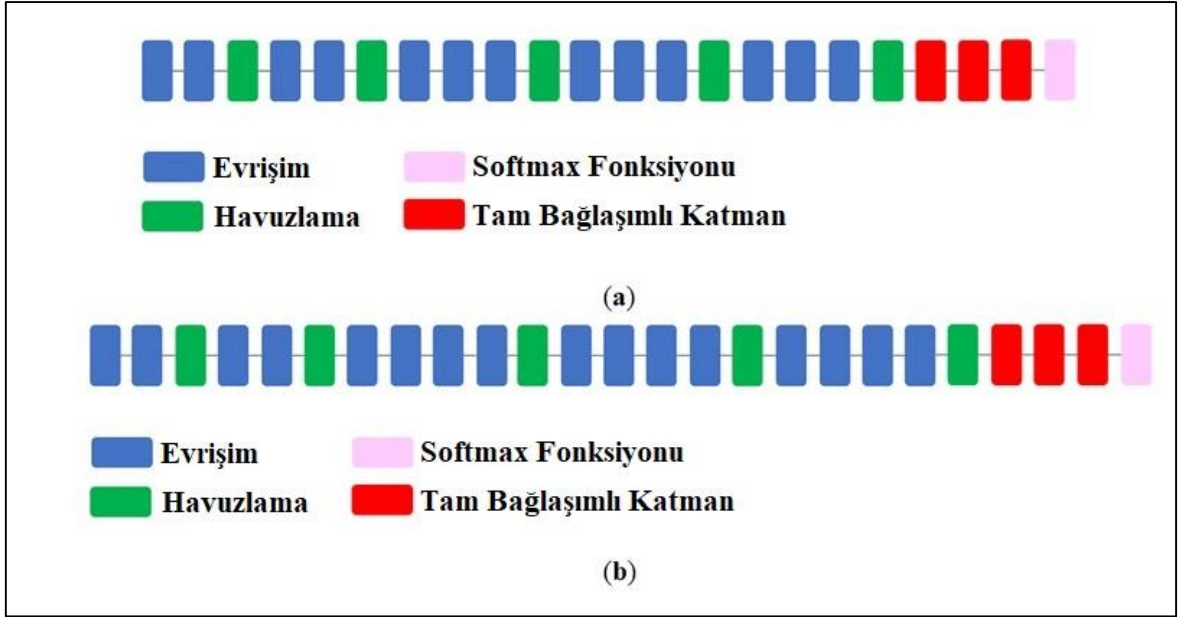
ResNet modeli, içerdiği derin katman sayısına göre ResNet-18, ResNet-50 ve ResNet-101 olmak üzere üç farklı sürüme sahiptir. Modeldeki derin katmanlar da açılarak hesaba katıldığında bu farklı sürümler sırasıyla 71, 177 ve 347 katmandan meydana gelmektedir.



Şekil 2.28. ResNet mimarisindeki artık blok yapısı.

2.5.4. VGGNet

2014 yılında düzenlenen yarışmada, GoogLeNet'in ardından ikinci seçilen ağdır. Ağ, AlexNet'e benzerliğiyle dikkat çeker. VGGNet, aynı ResNet mimarisi gibi içerdiği katman sayısına göre farklı sürümlere sahiptir. En çok tercih edilen modellerinden olan VGG-19; 16'sı evrişim, 3'ü tam bağlaşımlı olmak üzere toplamda 19 derin katmandan oluşur. Bu mimaride kullanılan filtreler 3×3 boyutundadır. VGG-19 modeli yaklaşık 144 milyon parametre içermektedir [66]. Benzer şekilde meydana getirilen VGG-16 modeli ise 138 milyon parametre içeren 16 derin katmana sahip olup yaygın olarak kullanılan diğer bir VGGNet sürümüdür. İki sürüme ait mimari yapılar, Şekil 2.29'da verilmiştir. Modeldeki derin katmanlar hesaba katıldığında VGG-16 ile VGG-19 mimarileri sırayla 41 ve 47 katmandan oluşmaktadır.

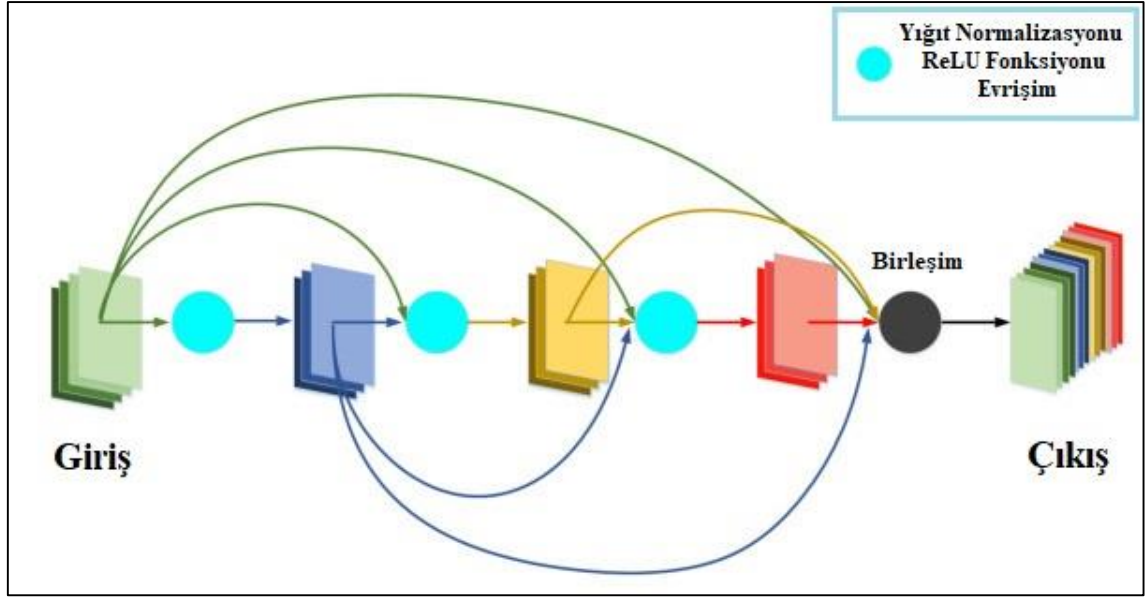


Şekil 2.29. a) VGG-16 mimarisi , b) VGG-19 mimarisi [67].

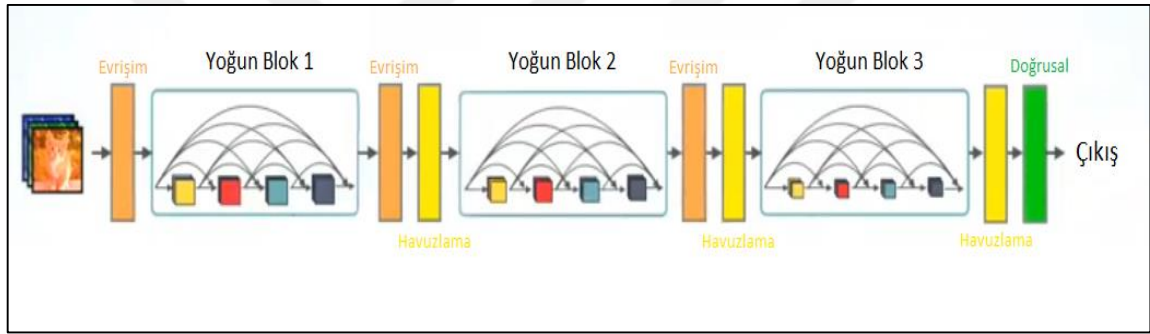
2.5.5. DenseNet-201

2018 senesinde ortaya çıkarılan bu mimari yapı, ResNet modeline benzer kısa yol bağlantılarını kullanarak kaybolan gradyan problemine çözüm getirmeyi amaçlamıştır. ResNet modelinden farklı olarak, DenseNet mimarisindeki öznetelik haritaları, bir sonraki öznetelik haritası ile toplanmaz. Bunun yerine öznetelik haritaları, birleştirme işlemine tabi tutulur. Ayrıca her katman, kendinden önceki katmanların tamamına bağlıdır ve parametre sayısı ResNet'e oranla daha azdır. ResNet'teki artık blok, bu yapıda yoğun bloğu (dense block) olarak adlandırılmaktadır. Bunlara ek olarak DenseNet-201 modeli 201 derin katman barındırmaktadır. Derin katmanlar açıldığında, modelin 805 bağlantısı bulunan 708 katmandan meydana geldiği gözlenmektedir [68].

Şekil 2.30'da bu mimariye ait kısa yol bağlantıları; Şekil 2.31'de ise mimari yapı katmanları gösterilmiştir.




Şekil 2.30. DenseNet mimarisindeki kısa yol bağlantıları [69].



Şekil 2.31. DenseNet mimarisi [68].

2.5.6. InceptionResNet-v2 (Inception-v2)

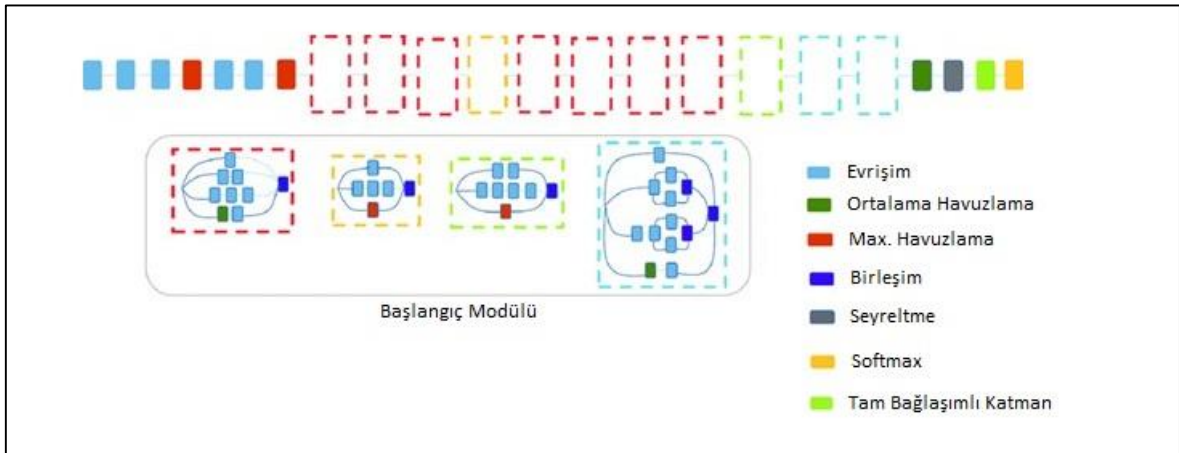
GoogLeNet modelinin performans açısından iyileştirilmiş sürümüdür. 3x3 yerine; 1x3 ve 3x1 filtreler gibi asimetrik evrişim katmanları barındırarak, parametre sayısı ve işlem maliyeti azaltılmaya çalışılmıştır [70]. 164 derin katman barındıran modele, Şekil 2.32’de yer verilmiştir.



Şekil 2.32. InceptionResNet-v2 (Inception-v2) mimarisi [67].

2.5.7. Inception-v3

Bir önceki sürümüne eklenen bazı katmanlar (küme normalizasyonu, evrişim katmanları, tam bağlaşımlı katmanlar) ile modelden alınan başarımlı artırımı hedeflenmiştir. Bu model, 350 bağlantıya sahip 316 katman barındırmaktadır. Daha çok sayıda; ancak daha küçük boyuttaki evrişim filtreleri tercih edilerek daha hızlı eğitim işlemi sağlanmıştır [71]. Derin ağ modeli, Şekil 2.33'te sunulmuştur.



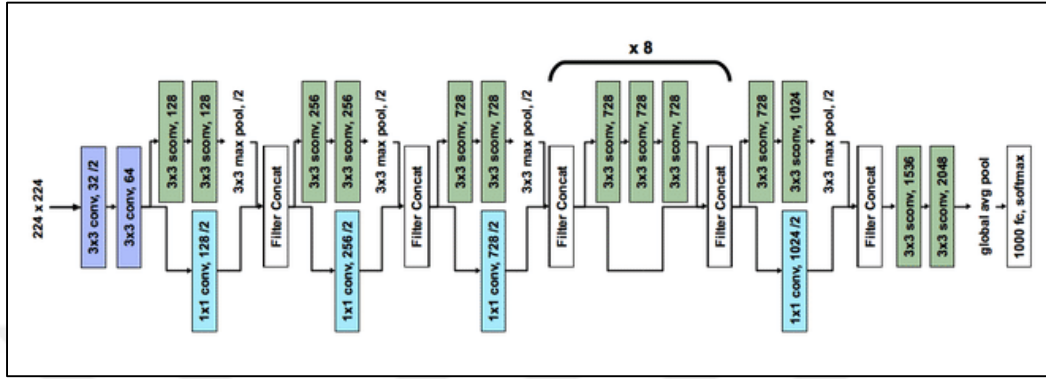
Şekil 2.33. Inception-v3 mimarisi [67].

2.5.8. Xception

“Xtreme Inception” anlamını taşıyan Xception modeli, Inception modüllerinin yerini ayrıştırılabilir evrişim modüllerinin aldığı bir Inception mimari sürümü olarak geçer. 2017

yılında çıkarılan model, içerdığı 23 milyon ağ parametresiyle ilk sürümü olan GoogLeNet ile yaklaşık aynı parametreye sayısına sahiptir [72].

Xception modülü, giriş akışı, orta akış (8 kez tekrarlamalı) ve çıkış akışı olmak üzere 3 ana bölümden meydana gelir. Mimari yapı Şekil 2.34'te verilmiştir.



Şekil 2.34. Xception mimarisi [73].

2.6. Destek Vektör Makineleri (Support Vector Machines, SVM)

Bu makine öğrenme algoritmasının temeli, iki sınıf arasında bir hiper düzlem çizerek verileri ayırma işlemine dayanmaktadır [74]. Bu yöntem, daha çok iki sınıftan oluşan verileri sınıflandırmada kullanılmaktadır; ancak çok sınıfa ait problemler için de farklı yaklaşımları bulunmaktadır.

Şekil 2.35'te sınıflandırıcının çalışma mantığını gösteren bir görsel yer almaktadır. Şekilde, iki sınıflı bir problem ele alınmıştır. Sınıflar pembe ve mor noktalar ile görselleştirilmiştir. Bu verilerin ayrıştırılabilmesi adına, iki sınıfı ayıran bir doğru çizilir. Her ne kadar veriler arasında sonsuz tane doğru çizilebilse de; önemli olan en uygun doğruyu belirleyebilmektir. En uygun doğru ise, iki sınıfa ait en yakın iki veri arasındaki uzaklığın maksimize edilmesiyle bulunur. Uzaklığın maksimize edilmesi için, farklı sınıflarda birbirine en yakın iki veri üzerinden birer doğru çizilir. Bu doğrular destek vektörleri olarak isimlendirilir ve bu iki doğru arasında kalan bölgeye marjin denir. Marjin, ne kadar geniş ise sınıflar o kadar yüksek doğruluk payı ile ayrıştırılabilir.

Sınıflandırma işleminde kullanılan karar fonksiyonu \hat{y} , (2.12)'de verilmiştir. SVM sınıflandırıcı ile yapılan sınıflandırma işleminde genellikle -1 ve +1 şeklinde sınıf etiketleri kullanılmaktadır [75].

$$\hat{y} = \begin{cases} -1, & w^T x + b < 0 \\ 1, & w^T x + b > 0 \end{cases} \quad (2.12)$$

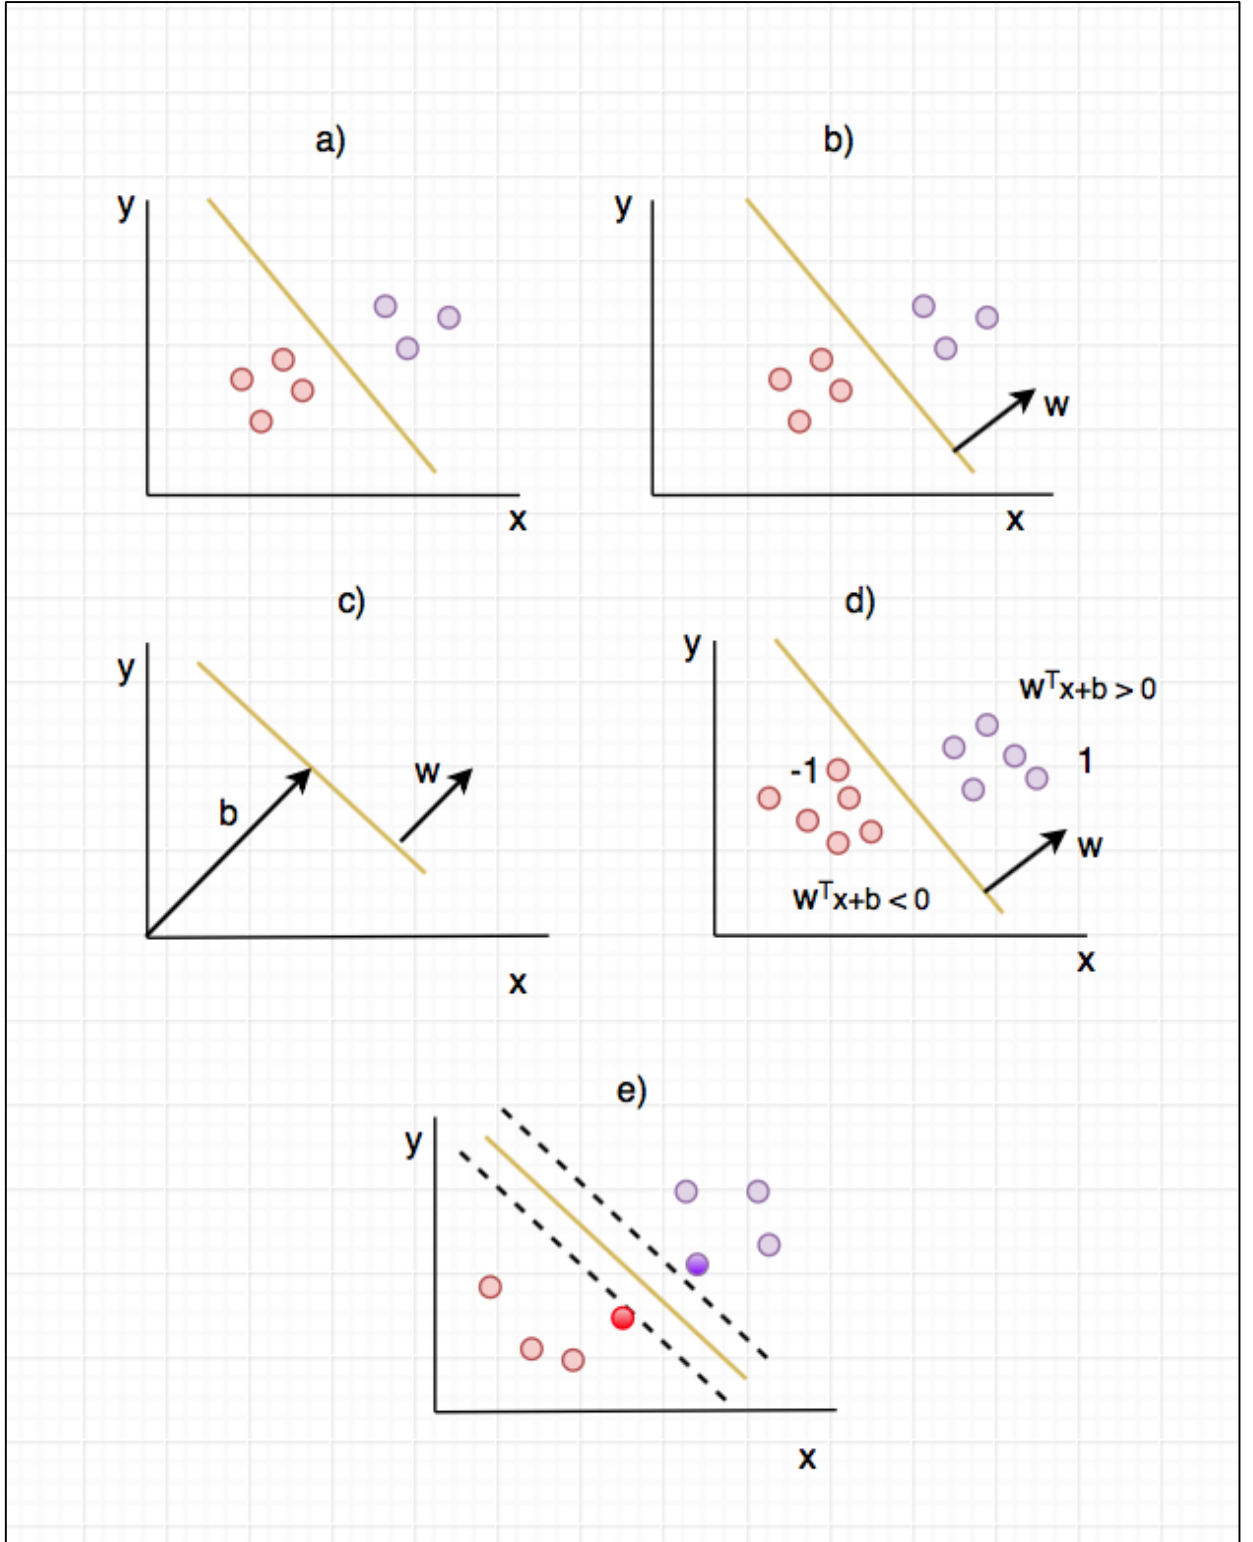
Denklemden w , ağırlık vektörünü; x , girdi vektörünü; b ise sapma değerini nitelemektedir. Buna göre, Şekil 2.35'te verilen bir nokta için denklem sonucu 0'dan küçük ise, pembe noktalara ait sınıfa daha yakındır; 0'dan büyükse, mor noktalara ait sınıfa daha yakındır olacaktır.

Yukarıda bahsedilen işlemler -1 ve +1 şeklinde iki sınıflı problem çözümü için geçerlidir. Ancak problem ikiden fazla sınıf sayısına barındırabilir. Bu gibi çoklu sınıf problemlerinde; bire karşı bir (one vs. one), bire karşı hepsi (one vs. all) gibi farklı SVM yaklaşımları vardır [76].

Bu yaklaşımlardan bire bir yaklaşımına göre, tüm sınıflar önce ikili gruplar halinde SVM ile eğitilmektedir. Ardından tüm SVM'ler birbiriyle kıyaslanarak hangi sınıf için en güvenilir sonucun çıktığına bakılmakta ve veri bu sınıfa atanmaktadır. Veri setinde kaç adet sınıf etiketi var ise eğitilecek SVM sayısı da ona göre farklılaşır. Örneğin N sınıflı bir veri seti için, $N*(N-1)/2$ adet SVM eğitilmelidir. A, B ve C etiketlerini barındıran 3 sınıflı bir veri seti için eğitilen birinci SVM; A ve B etiketli sınıfları, ikinci SVM; A ve C etiketli sınıfları, üçüncü SVM ise; B ve C etiketli sınıfları birbirinden ayırır. Yani her sınıf ikilisi için bir SVM eğitilir. Çok sınıflı veriler için maliyetli bir yöntemdir.

Bire karşı hepsi yaklaşımında ise; veri setinden alınan bir veri, bir sınıfa dahil edilir. Geri kalan tüm sınıflar, tek bir sınıf gibi kabul edilerek diğerleriyle karşılaştırılır. Eğitim kümesindeki her veri, diğer tüm veriler ile kıyaslandığı için sınıf sayısı kadar SVM oluşturulmuş olur.

SVM'nin literatürde en başarılı metotlardan biri olarak görülmesi, bu tez kapsamında yapılan çalışmaların sınıflandırıcısı olarak seçilme nedeni olmuştur [77].



Şekil 2.35. SVM sınıflandırıcının çalışma prensibini anlatan bir görsel [75].

2.7. k-En Yakın Komşu Algoritması (k-Nearest Neighbours, k-NN)

Bu yöntem, örnek tabanlı en basit makine öğrenme algoritmalarının başında gelir. Öğrenme işlemi veri setinde yer alan örneklere göre yapılarak, sınıflandırma işlemi sırasında bu örnekler ile yeni gelen örnekler arasındaki mesafeye bakılır [78].

Bu makine öğrenmesi algoritmasında, k parametresi en yakın komşu sayısını ifade eder. Buna göre test setinden yeni gelen bir örnek ile karşılaştırıldığında, eğitim setinden en yakın k adet örnek seçilir ve sınıf etiketlerine bakılır. Bakılan k tane örnekten en çok hangi sınıfa ait etiket var ise, yeni gelen örneğin de o sınıfa ataması yapılır. Böylece yeni gelen veri, örnekler arasındaki mesafe temel alınarak sınıflandırılmış olur.

Algoritma işleyişi basit ve küçük boyutlu veri setleri için oldukça etkilidir. Ancak her yeni gelen örnek ile ona en yakın k tanesi kıyaslandığı için büyük boyutlu veri setleri söz konusu olduğunda, işlem maliyeti çok yüksek olur [79].

k-NN algoritmasında, mesafe hesabı yapılırken farklı uzaklık ölçütleri kullanılabilir. Bunların başında Öklid (Euclidean), Minkowski, Manhattan ve Chebyshev uzaklığı gelmektedir. En sık kullanılan Öklid mesafesi için genel formül, (2.13)'de verilmiştir.

$$d(x, y) = \sum_{i=1}^n (x_i - y_i)^2 \quad (2.13)$$

Formülde $A = (x_1, x_2, x_3, \dots, x_n)$ ve $B = (y_1, y_2, y_3, \dots, y_n)$ veri uzayında herhangi iki nokta olmak üzere, d hesaplanan uzaklığı temsil etmektedir [80].

En yakın k komşuluk algoritmasının basit işleyişi aşağıdaki gibidir:

1. k değeri seçilir.
2. Veri setinde yer alan veriler ile yeni gelen veri arasındaki uzaklıklar hesaplanır.
3. Hesaplanan uzaklıklar küçükten büyüğe sıralanır.
4. En küçük uzaklığa sahip k tane uzaklık (k tane komşu) belirlenir.
5. k tane komşunun etiket bilgilerine bakılarak kaçar adet olduğu sayılır.
6. En çok sayılan etiket bilgisi, yeni gelen verinin etiketi olur.

2.8. Kolektif Öğrenme (Ensemble Learning)

Klasik sınıflandırma yaklaşımlarında, probleme özgü en iyi sonucu ürebilen bir sınıflandırıcı eğitilerek sınıflandırma işlemi yapılır. En iyi sonucun bulunması deneme-yanılma yöntemiyle gerçekleşir ve problemi çözmeye bir adet model kullanılır. Kolektif öğrenmede ise klasik sınıflandırmadan farklı olarak birden fazla modelleyici algoritmanın birlikte kullanılarak yeni bir model oluşturulması yaklaşımı vardır.

Kolektif öğrenmenin farklı çeşitleri mevcuttur. Bunların başlıcaları torbalama (bagging) ve yükseltme (boosting)'dir.

2.8.1. Torbalama (Bootstrap Aggregation, Bagging) Tekniği

Breiman tarafından 1996 yılında ortaya atılan bu teknik, orijinal veri setinden tekrar yerine konulacak şekilde yeni eğitim setleri üreterek ana modeli yeniden eğitmeyi hedefler. Bu teknikte sırayla aşağıdaki adımlar izlenir:

1. Orijinal veri seti alt kümelere bölünür.
2. Her alt kümenin eğitim işlemi bir makine öğrenmesi algoritması kullanılarak gerçekleştirilir ve her biri için yeni bir model oluşturulur.
3. Tüm modeller birbirinden bağımsız olacak şekilde paralel çalıştırılır.
4. Tüm modellerden gelen çıktılar birleştirilerek nihai çıktı üretilir.

2.8.2. Yükseltme (Boosting) Tekniği

Bu tekniğin temelinde birden fazla öğrenciyi bir araya getirerek güçlü bir sınıflandırıcı yaratma fikri vardır. Tahminleyici model olarak genellikle karar ağaçları (decision trees) tercih edilir [81].

Bu teknikte AdaBoost (Adaptive Boosting), Gradient Boosting, XGBoost, LightGBM, CatBoost gibi farklı yükseltme modelleri vardır. En çok tercih edilen ve ilk yükseltme algoritması olarak kabul edilen model AdaBoost'dur [82]. Torbalama tekniğinden farkı; paralel yerine sıralı bir yapıya sahip olması sebebiyle ilk aşamalarda yapılan hatanın sonraki aşamaları etkilemesidir. AdaBoost yükseltme tekniği için sırasıyla aşağıdaki adımlar izlenir:

1. Orijinal veri kümesinden bir alt küme meydana getirilir.

2. Kümedeki tüm gözlemlere eşit olacak şekilde ağırlık katsayıları atanır ve ilk model oluşturulmuş olur.
3. Bu model kullanılarak tüm veri kümesi için tahminler yapılır.
4. Tahminlerin doğruluğuna bakılarak hata hesaplaması yapılır.
5. Yanlış öngörülen gözlemlere ait ağırlık katsayıları artırılır ve yeni bir model oluşturulmuş olur.
6. Yeni oluşturulan model kullanılarak tekrar tahminler yapılır ve benzer şekilde hataları azaltmayı hedefleyen yeni modeller meydana getirilir.
7. Nihai model, oluşturulan tüm modellerin ağırlıklı ortalaması olur [83].

2.9. Naive Bayes Sınıflandırıcısı

Bu sınıflandırıcı, adını ve temelini Bayes teoreminden alan olasılık temelli bir sınıflandırıcıdır. Bayes teoremi matematiksel olarak (2.14) ile ifade edilir.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.14)$$

Denklemden;

$P(A)$, A olayının önsel olasılığı (Tecrübeye dayalı A olayının olasılığı),

$P(B)$, B olayının önsel olasılığı (Tecrübeye dayalı B olayının olasılığı),

$P(A|B)$, B olayı gerçekleştiği durumda A olayının meydana gelme olasılığı,

$P(B|A)$, A olayı gerçekleştiği durumda B olayının meydana gelme olasılığını ifade etmektedir [84].

Naive Bayes sınıflandırıcısı ise bu teoremi temel alarak her durum için ayrı bir olasılık değeri hesaplar ve bu değerler arasında en yüksek değere sahip olan etiket verisine göre karar vererek sınıflandırma işlemini yapar [85].

2.10. Sınıflandırma Performansını Ölçmede Kullanılan Teknikler

Sınıflandırıcının doğruluğunu göstermek adına çeşitli metrikler kullanılabilir. En yaygın kullanılan metriklerden biri karmaşıklık matrisi, diğeri ise F1 skoru değeridir. Tez kapsamında yapılan çalışmalarda da bu metrikler üzerinden sınıflandırıcı performansı irdelenmiştir.

a) Karışıklık matrisi (confusion matrix): Karışıklık ya da karmaşıklık matrisi, bir sınıflandırıcının performansını temsil eder. İkili sınıflandırma için oluşturulan bir karmaşıklık matrisi Şekil 2.36'da gösterilmiştir.

Gerçek Değerler	Tahmini Değerler	
	TP (Gerçek Pozitifler)	FN (Yanlış Negatifler)
FP (Yanlış Pozitifler)	TN (Doğru Negatifler)	

Şekil 2.36. Karmaşıklık matrisi.

Matriste geçen gerçek negatif (True Negative, TN) parametresi, doğru olarak sınıflandırılan negatif örneklerin sayısını gösterir. Benzer şekilde, gerçek pozitif (True Positive, TP), doğru olarak sınıflandırılan pozitif örneklerin sayısını gösterir. Yanlış pozitif (False Positive, FP), pozitif olarak sınıflandırılan gerçek negatif örneklerin sayısı anlamına gelir; yanlış negatif (False Negative, FN), negatif olarak sınıflandırılan gerçek pozitif örneklerin sayısıdır [86]. Yani ikili bir sınıflandırma işlemi için şu şekilde basitleştirilebilir:

- Gerçek negatif (TN): Sınıflandırıcı tarafından 0 olarak sınıflandırılan ve gerçekte de 0 olan değerlerin sayısıdır.
- Gerçek pozitif (TP): Sınıflandırıcı tarafından 1 olarak sınıflandırılan ve gerçekte de 1 olan değerlerin sayısıdır.
- Yanlış pozitif (FP): Sınıflandırıcı tarafından 1 olarak sınıflandırılan; fakat gerçekte 0 olan değerlerin sayısıdır.

- Yanlış negatif (FN): Sınıflandırıcı tarafından 0 olarak sınıflandırılan; fakat gerçekte 1 olan değerlerin sayısıdır.

Tez adına yapılan tüm çalışmada, tüm modellerin sınıflandırma başarımları (2.15) kullanılarak hesaplanmıştır.

$$\text{Sınıflandırma Başarısı} = (TP + TN) / (TP + TN + FN + FP) \quad (2.15)$$

b) F1 Skoru (F1 score): Bu değer yine sınıflandırıcı doğruluğunu gösterme maksadıyla kullanılır. F1 skor değerini hesaplamak için gereken formül (2.16)'da verilmiştir. Bu denklemdaki parametreleri elde etmek için; karmaşıklık matrisi içindeki bazı değişkenler kullanılır.

$$\text{F1 skoru} = 2 / ((1 / \text{hassasiyet}) + (1 / \text{kesinlik})) \quad (2.16)$$

Kesinlik (precision), sınıflandırıcı tarafından doğru sınıflandırılan verilerin oranını verir ve (2.17)'deki gibi hesaplanır. (2.18)'de ifade edilen hassasiyet (sensitivity) ise sadece pozitif değerlerden doğru sınıflandırılan verilerin oranını verir. Bu durumda F1 skoru, kesinlik ve hassasiyet değerlerinin harmonik ortalamasına eşittir.

$$\text{Kesinlik} = TP / (TP + FP) \quad (2.17)$$

$$\text{Hassasiyet} = TP / (TP + FN) \quad (2.18)$$

Ayrıca bunların dışında kullanılan belirlilik (specificity) adı verilen bir ölçüt daha vardır. Bu değer, sadece negatif olarak sınıflandırılan verilerin gerçekteki negatif verilere oranını verir. Hesaplanışı (2.19)'daki gibidir.

$$\text{Belirlilik} = TN / (TN + FP) \quad (2.19)$$

3. TEZ KAPSAMINDA YAPILAN ÇALIŞMALAR

Bu bölümde doktora tezi kapsamında oluşturulan veri seti ile yapılan tüm çalışmalara detaylı olarak yer verilmiştir.

3.1. Köpeklerdeki Uzun Kemiklerin Sınıflandırılması


Köpeklerdeki uzun kemik çeşitleri altı sınıfta incelenmektedir. Bunlar:

1. Femur
2. Humerus
3. Tibia
4. Radius
5. Ulna
6. Fibula'dır.


Radius ve ulna kemikleri köpeklerin ön kol kemiklerini oluşturur ve bu bölgede kırık meydana gelmesi durumunda, kırık genellikle iki kemik üzerinde de olur. Bu sebeple bu kemikler, radius-ulna adı altında tek bir uzun kemik sınıfı etiketiyle değerlendirilmiştir. Öte yandan uzun kemik çeşitlerinden biri olan fibula kemiği, aksesuar kemik olup vücut yükünü taşımada etkin rol oynamadığı için; çalışmalarda bu kemiğe ait bir sınıf etiketi oluşturulmamıştır.

Veri setinin daha iyi anlaşılması adına köpeklerdeki uzun kemikleri belirten bir görsel Şekil 3.1'de sunulurken; veri setindeki örnek X-ray görüntülerine Şekil 3.2'de yer verilmiştir.

Oluşturulan veri setinde 671 adet femur, 264 adet humerus, 268 adet radius-ulna ve kalan 554 adedi de tibia olacak şekilde toplamda 1757 adet görüntü, köpeklerdeki uzun kemiğin cinsine göre dört farklı sınıfa ayrılmıştır. Veri setinin uzun kemiklere göre ayrımı ve görüntü sayıları Tablo 3.1'de verilmiştir.



Şekil 3.1. Köpeklerde uzun kemikler [87].



Şekil 3.2. Veri setinde yer alan uzun kemik çeşitlerine birer örnek a) femur, b) humerus, c) radius-ulna ve d) tibia.

Bu çalışmada görüntü işlemedeki başarısı nedeniyle CNN algoritması kullanılmıştır [88]. Veri setinde farklı sınıfların farklı görüntü sayılarına sahip olması sebebiyle, her sınıftan rasgele seçilen 264'er görüntü modele girdi olarak verilmiştir. Algoritmada eğitim ve test kümeleri veri setinden rastgele seçilmiş olup tüm veri setine oranları sırasıyla %80 ve %20 olarak belirlenmiştir. Algoritmada yığın boyutu 32 olarak seçilmiştir.

Tablo 3.1. Veri setindeki görüntü sayıları

Kemik Adı	Görüntü Sayısı
Femur	671
Humerus	264
Radius-Ulna	268
Tibia	554

Ham veriler CNN modeline uygulanarak görüntüdeki öznitelikler elde edilmiş, ardından farklı makine öğrenmesi algoritmaları ile bu veriler sınıflandırılmıştır. Veri setine en uygun sınıflandırıcıyı belirleyebilmek adına; seçilen bir derin ağ modelinden elde edilen öznitelikler, literatürde en çok tercih edilen dört farklı sınıflandırıcı ile test edilmiştir. AlexNet'in tam bağlaşımlı katmanından alınan çıktı matrisi; çok sınıflı destek vektör makineleri, Naive Bayes Sınıflandırıcısı, k-en yakın komşuluk algoritması ve yükseltme tekniklerinden biri olan AdaBoost algoritmasına tabi tutulmuştur.

En yakın k komşuluk algoritmasında k değeri 5 olarak belirlenmiş, uzaklık ölçütü Öklid olarak alınmıştır. Destek vektör makineleri yönteminde ise bire karşı hepsi yaklaşımı kullanılmıştır.

Sınıflandırıcı çeşidine göre elde edilen doğruluk değerleri ve karmaşıklık matrisleri sırasıyla Tablo 3.2 ve 3.3'te verilmiştir.

Makine öğreniminde sınıflandırma görevi için en iyi olarak lanse edilen bir algoritma yoktur. Algoritmaların bazıları, bazı veri setleri ve uygulamalarda diğerlerinden iyi çalışırken; bazıları çok kötü sonuçlar yaratabilir. Bu sebeple, tez kapsamında oluşturulan veri seti için en iyi sınıflandırıcı seçilmek istenmiş ve popüler yöntemler ile kıyaslama yapılmıştır. Tablo 3.2 ve 3.3 incelendiğinde, destek vektör makinelerinin diğer metotlara oranla çok başarılı olduğu gözlenmektedir. Bu çalışmadan alınan sonuçlar ışığında, literatürdeki öğrenme aktarımı ile yapılan sınıflandırma çalışmalarında olduğu gibi, tez çalışmalarında da SVM sınıflandırıcısının kullanılabilceği gösterilmiştir [89].

Tablo 3.2. Sınıflandırıcı çeşidine göre sınıflandırma başarıları

Sınıflandırıcı Çeşidi	Sınıflandırma Başarısı (%)
Destek Vektör Makineleri	91,51
Naïve Bayes Sınıflandırıcısı	77,83
k-En Yakın Komşuluk Algoritması	83,86
AdaBoost Yükseltme Algoritması	80,19

Görüntülerin sınıflandırma performansını ölçerek, veri setine en uygun derin ağ yapısını belirlemek amacıyla da en popüler üç mimari ile öğrenme aktarımı gerçekleştirilmiş, SVM ile sınıflandırılma işlemi yapılmış ve elde edilen tüm sonuçlar Tablo 3.4’te özetlenmiştir.

Tablo 3.3. Sınıflandırıcı çeşidine göre oluşturulan karmaşıklık matrisleri

Sınıflandırıcı Çeşidi	Karmaşıklık Matrisi				Belirlilik (%)
	<i>Humerus</i>	<i>Radius-Ulna</i>	<i>Tabia</i>	<i>Femur</i>	
Destek vektör makineleri	47	2	1	3	88,68
	0	48	4	1	90,57
	1	3	48	1	90,57
	0	0	2	51	96,23
Duyarlılık (%)	97,92	90,57	87,27	91,07	91,51 91,71
Naive Bayes Sınıflandırıcısı	44	2	3	4	83,02
	2	38	10	3	71,70
	5	9	37	2	69,81
	2	3	2	46	86,79
Duyarlılık (%)	83,02	73,08	71,15	83,64	77,83 77,72
k-en yakın komşuluk algoritması	45	2	0	6	84,90
	1	42	8	2	79,24
	2	7	43	1	81,13
	0	1	4	48	90,57
Duyarlılık (%)	93,75	80,77	78,18	84,21	83,96 84,23
AdaBoost Algoritması	47	2	2	2	88,68
	2	43	7	1	81,13
	4	7	39	3	73,58
	3	3	6	41	77,36
Duyarlılık (%)	83,93	78,18	72,22	87,23	80,19 80,39

Tablo 3.4. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	91,51
GoogLeNet	87,74
VGG-19	86,79

Öğrenme aktarımı, derin öğrenmede en sık başvurulan yöntemdir. Çünkü derin öğrenme modelleri, eğitilmek için çok fazla veri ve bununla beraber de performansı yüksek bir donanım ihtiyacı duyar. Dolayısıyla önceden eğitilmiş bir ağı kullanmak, ağı baştan eğitmeye oranla daha kısa zamanda iyi sonuçların elde edilebileceği bir yöntem olarak karşımıza çıkar [90].

Bu çalışmada da üç farklı eğitilmiş ağ ile sınıflandırma performansı karşılaştırılmak istenmiştir. Sonuçlara göre, en iyi sınıflandırma başarısının yüzde 91,51'lik başarıyla AlexNet ile yakalandığı görülmektedir. Buna karşın; GoogLeNet ile VGG-19 mimarilerine ait başarıların birbirine yakın olduğu görülmektedir. Buradan hareketle öğrenme aktarımı yönteminin, literatürdeki benzer çalışmalar gibi, bu çalışmada kullanılan veri seti için de etkili olduğunu söylenebilir [91]. Çünkü bu üç mimari de öncesinde büyük görüntü boyutlarında eğitilmiş ve farklı sınıflar için modelini genelleştirmeyi başarabilmiştir. Bunun yanında, Tablo 3.4'teki değerler kıyaslandığında, en az katmana sahip model olan AlexNet'in en iyi performansı verdiği fark edilmektedir. Bu çıktı, kemik çeşidini sınıflandırmak için çok derin ağlara ihtiyaç duyulmadığına dair bir ispat niteliği taşımaktadır. Ayrıca insandaki uzun kemiklerin sınıflandırılması üzerine yapılan benzer başka bir çalışma için 6 katmanlı bir CNN modeli ile yüksek başarılar elde edildiği tespit edilmiştir [92].

Sınıflandırma performansını daha iyi irdelemek adına, üç model için de oluşturulan karmaşıklık matrislerine Tablo 3.5'te yer verilmiştir.

Tablo 3.5. Ağ mimarilerine göre oluşturulan karmaşıklık matrisleri

Mimari Yapı	Karmaşıklık Matrisi				Belirlilik (%)
	<i>Humerus</i>	<i>Radius-Ulna</i>	<i>Tabia</i>	<i>Femur</i>	
AlexNet	47	2	1	3	88,68
	0	48	4	1	90,57
	1	3	48	1	90,57
	0	0	2	51	96,22
Duyarlılık (%)	97,92	90,57	87,27	91,07	91,51 91,71
GoogLeNet	46	1	3	3	86,80
	1	47	5	0	88,68
	1	2	49	1	92,45
	4	0	5	44	83,02
Duyarlılık (%)	88,46	94,00	79,03	91,67	87,74 88,29
VGG-19	51	0	0	2	96,22
	3	43	7	0	81,13
	2	4	46	1	86,80
	5	0	4	44	83,02
Duyarlılık (%)	83,61	91,49	80,70	93,62	86,79 87,35

Bu çalışmaya ek olarak, sıfırdan öğrenme ile öğrenme aktarımı işlemlerinin karşılaştırılması da yapılmak istenmiştir. Bu sebeple sıfırdan oluşturulan 15 katmanlı bir ağ kullanılarak boyutları 200x200 olarak belirlenen girdi görüntüleri, kemik tipine göre sınıflandırılmış; bu işlem için sınıflandırma başarısı %70,94 olarak hesaplanmıştır. Sıfırdan oluşturulan ağ sırasıyla aşağıdaki katman ve parametreleri içerir:

- Giriş katmanı
- Evrişim katmanı (8 adet 3x3 boyutlarında kernel)
- Yığıt normalizasyon katmanı

- ReLu katmanı
- Maksimum havuzlama katmanı (havuzlama boyutu: 2, kayma miktarı: 2)
- Evrişim katmanı (16 adet 5x5 boyutlarında kernel)
- Yığıt normalizasyon katmanı
- ReLu katmanı
- Maksimum havuzlama katmanı (havuzlama boyutu: 2, kayma miktarı: 2)
- Evrişim katmanı (32adet 3x3 boyutlarında kernel)
- Yığıt normalizasyon katmanı
- ReLu katmanı
- Tam bağımlı katman (düğüm sayısı: 4)
- Softmax katmanı
- Sınıflandırma katmanı

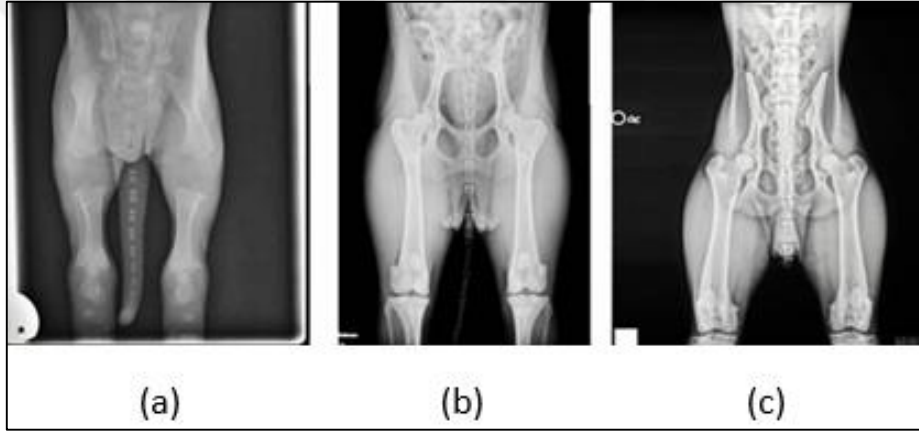
Alınan sonuçlar karşılaştırıldığında; öğrenme aktarımı yönteminin çok daha başarılı sonuçlar ortaya koyduğu açıkça görülmektedir. Her iki yöntemde de daha yüksek başarılar elde etmek; ağ yapılarının optimize edilmesi ve veri setinin çoğaltılması ile mümkün olabilir. Ancak sıfırdan oluşturulan ağın optimize edilmesi çok daha güçtür. Bu nedenle, ilerleyen çalışmalarda öğrenme aktarımı yöntemi ile daha farklı ağ mimarileri farklı görevlerde denenerek başarı karşılaştırmaları yapılmıştır.

3.2. X-ray Görüntülerinden Köpeklerin Yetişkinlik Düzeyinin Belirlenmesi


Uzun kemiklerin cinsine göre incelenen sınıflandırma başarısının umut vaat etmesi, ardından gelecek birçok çalışmaya zemin hazırlamıştır. Bilgi dahilinde yapılan yayınlarda incelenmemiş konulardan bir tanesi de kemik görüntüleri kullanılarak köpeklerdeki yetişkinlik düzeyinin tahmin edilmesidir. Bu alt çalışmada, kırık olmayan uzun kemikler incelenerek genç-yetişkin köpek ayrımının yapılması hedeflenmiştir. Genç olarak etiketlenen köpekler 0-1 yaş aralığında iken; yetişkin sınıfına alınan köpekler ise 1

yaşından büyük köpekler olarak sadece X-ray görüntüsüne bakılarak uzman veteriner ortopedist tarafından kategorize edilmiştir. Etiketleme işlemi bu alt çalışma için zorlu bir görev olmuştur. Çünkü veri seti sahipsiz hayvan görüntüleri ile oluşturulduğundan, köpeklerin yaşı tam olarak bilinmemektedir.

Veteriner hekimler, radyografları kullanarak bir hayvanın olgunluk düzeyini tahmin edebilirler. Çünkü köpekler de dahil olmak üzere çoğu memelide, cinsel olgunluğa erişildikten sonra kemik uçlarında yer alan büyüme plakaları (epifiz plakaları) kapanır ve ardından kemik büyümesi durur [93]. Şekil 3.3 ve Şekil 3.4, genç ve yetişkin köpeklere ait radyografları ve kemiklerindeki büyüme plakalarını karşılaştırmaktadır. Şekillerden de anlaşılacağı üzere, yavru köpektaki büyüme plakası hala açık iken yetişkin köpektaki ise daha belirgin durumdadır.



Şekil 3.3. Yaşlarına göre köpek radyografları. a) 2 haftalık köpek yavrusu, b) 7 haftalık köpek yavrusu ve c) 1 yaşındaki yetişkin köpek [94].




Şekil 3.4. Yavru ve yetişkin köpeklere ait büyüme plakaları. a) yetişkin (büyüme plakası kapalı), b) yavru (büyüme plakası hala açık) [95].

Regresyon yöntemleri [96-98] ve CNN tabanlı derin öğrenme mimarilerin [99-101] kemik yaşı tahmini amacıyla kullanıldığı pek çok çalışma mevcut olsa da yayınlarda bahsedilen çeşitli kısıtlamalardan dolayı, bu başarı oranlarının çok yüksek seviyelerde olmadığı fark edilmektedir. Bu alanda fazla görüntü içeren veri setlerinin olmaması ve var olan veri setlerinin yüksek doğruluk oranıyla etiketlenilememesi, literatürde incelenen çoğu çalışmanın ortak kısıtlama faktörü olarak karşımıza çıkmaktadır.

Çalışmanın çıktısı, operasyon öncesinde veteriner hekimlere yol gösterici bir araç olarak kullanılabilir. Çünkü operasyon öncesinde, hayvanların yetişkinlik düzeyi ile ağırlığına bakılarak anestezi dozu ayarlaması yapılır. Bu ayarlamamanın yanlış yapılması, ameliyat sırasında ve sonrasında ciddi problemlere neden olabilir [102]. Bu bağlamda yapılan bu alt çalışma çıktıları, literatür için oldukça faydalı bulunmaktadır.

Alt çalışmada, 500'ü genç, 500'ü ise yetişkin olmak üzere toplamda 1000 adet X-ray görüntüsü kullanılmıştır. Görüntülerin tamamı sağlam uzun kemiklere ait olup çalışmada kemik cinsi, köpek ırkı, cinsiyeti vb. parametreler dikkate alınmamıştır. Veri setinden örnek görüntüler ve kırmızı dikdörtgen içine alınan büyüme plakaları Şekil 3.5'te gösterilmiştir.



Şekil 3.5. Oluşturulan veri setinden örnek genç ve yetişkin köpek görüntüleri. a) genç köpek ve b) yetişkin köpek.

İlk çalışmada olduğu gibi, öğrenme aktarımı yöntemi bu alt çalışma için de test edilmiştir. Çalışmada, en sık kullanılan derin sinir ağlarından AlexNet, ResNet-50 ve GoogLeNet tercih edilmiştir. Ham veriler CNN modellerine uygulanarak görüntüdeki öznitelikler elde edilmiş ve ardından çok sınıflı destek vektör makineleri ile

sınıflandırılmıştır. Karşılaştırma adına da destek vektör makineleri hem öznelik çıkarmada hem de sınıflandırmada bir makine öğrenmesi yöntemi olarak uygulanmıştır. SVM, herhangi bir derin ağ olmadan öznelik çıkarma ve sınıflandırma konusunda başarısını yüksek boyutlu veri setleriyle kanıtladığı için bu çalışmada da tercih sebebi olmuştur.

Tüm algoritmalara girdi olarak verilen görüntüler 200x200x3 piksel olacak şekilde boyutlandırılmıştır. Veri seti, 1:4 oranında sırasıyla test ve eğitim seti olmak üzere rastgele ayrılmıştır. Tüm sonuçlar Tablo 3.6’da özetlenmiştir.

Sonuçlara göre, en iyi sınıflandırma başarısı 76,5 yüzdesiyle ResNet-50 mimarisine aittir; onu %74 başarısıyla GoogLeNet takip etmektedir. Tablodaki sonuçlardan; ResNet-50, GoogLeNet ve AlexNet sırasıyla 50, 22 ve 8 katmandan oluştuğu için ağın derinliğini artırmanın sınıflandırma doğruluğu açısından olumlu sonuçlar doğurduğu gözlemi yapılabilir. Hayvanların olgunluğunun kemik kenarlarındaki küçük detaylarda saklı olduğu düşünülünce, araştırma sonucunda elde edilen bulgu oldukça anlamlıdır.

Tablo 3.6. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	63,50
GoogLeNet	74,00
ResNet-50	76,50
SVM	72,50

Tablo 3.7. Çoğaltılmış veri kümesi ile ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	71,00
GoogLeNet	77,25
ResNet-50	80,00
SVM	65,25

Ayrıca, arařtırmada elde edilen sonuçlar, insan tabanlı veri setleri ile yapılmıř çalıřmalardaki ile kıyaslandığında sonuçların oldukça benzer olduđu yorum yapılabilir. Bu da, öğrenme aktarımı yönteminin, yine bu çalıřma için de uygun olduđunun bir göstergesidir. Öte yandan elde edilen sonuçlar, bu arařtırma konusunun insan tabanlı veri setleri ile yapılan çođu çalıřma gibi ele alınabileceđini göstermiřtir.

Aynı çalıřma, modellerin güvenilirliđini artırmak amacıyla çođaltılmıř veri ile de test edilmiřtir. Literatürde birçođ veri artırma yöntemine karřılık; en temel yöntemlerden biri olan görüntünün kontrast ayarını deđiřtirmek, uygulama kolaylıđı nedeniyle bu çalıřma ve ilerleyen çalıřmalarda da (Bölüm 3.3 ile Bölüm 3.4) tercih edilmiřtir [103]. Çođaltma iřleminde kontrast limitleri tam tersine döndürölerek (0 - 1) ile (1 - 0) olarak alınmıř ve veri kümesindeki görüntü sayısı iki katına çıkarılmıřtır. Çođaltılmıř veri ile elde edilen başarımlar Tablo 3.7'de sunulmuřtur. İki çalıřmadan elde edilen karmařıklık matrisleri ile F1 skoru deđerlerine Tablo 3.8'de verilmiřtir.

Tablo 3.8. Ham ve çoğaltılmış veri kümeleri ile ağ mimarilerine göre oluşturulan karmaşıklık matrisleri

Mimari Yapı		Ham Veri Seti		Çoğaltılmış Veri Seti	
		Tahmini Değerler		Tahmini Değerler	
AlexNet	Gerçek Değerler	<i>Genç</i>	<i>Yetişkin</i>	<i>Genç</i>	<i>Yetişkin</i>
		55	45	127	73
		28	72	43	157
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,72	0,61	0,78	0,68
F1 Skoru: 0,66		F1 Skoru: 0,73			
GoogLeNet		79	21	150	50
		31	69	41	159
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,69	0,76	0,79	0,76
		F1 Skoru: 0,72		F1 Skoru: 0,77	
ResNet-50		82	18	158	42
		29	71	38	162
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,71	0,79	0,81	0,79
	F1 Skoru: 0,75		F1 Skoru: 0,80		
SVM	69	31	144	56	
	24	76	84	116	
	Hassasiyet	Kesinlik	Hassasiyet	Kesinlik	
	0,76	0,71	0,58	0,67	
	F1 Skoru: 0,73		F1 Skoru: 0,62		


3.3. X-ray Görüntülerinden Uzun Kemik Kırıklarının Zamana Göre Sınıflandırılması

Bu alt çalışmanın amacı, literatürde aydınlatılmayan bir başka konu olan kemik kırıklarının oluşum zamanına göre sınıflandırılmasıdır. Bu bilgi, kırığı onarmak için yapılan ameliyatın ne kadar zor olacağını konusunda veteriner hekimlere önsezi sağlayabilir. Ayrıca çoğu benzer ortopedik problemlerden mustarip olan sokak hayvanlarında, sahip olunan kısıtlı kaynaklar altında cerrahi önceliğin belirlenebilmesi adına da fayda sağlayabilir. Çünkü kemik, malunion adı verilen yanlış pozisyonda iyileşmeye başlar ve üzerinden bir süre geçerse eski kırık olarak nitelendirilir. Bu gibi kaynamaya başlamış kemik kırıkları içeren vakalarda, operasyon daha zorlu geçer [104].


Çalışmada uzun kemik kırıkları, yeni kırıklar ve eski kırıklar olmak üzere iki sınıfta incelenmiştir. Ayrıca kaynamış kırıklar da eski kırık kemik etiketi altına tasnif edilmiştir. Çalışmadaki yeni kırık etiketi, kemiğin kırılmasının bir haftadan az bir zamanda gerçekleşmiş olmasına; eski kırık etiketi ise bu sürecin bir haftadan fazla olmasına göre verilmiştir. Bu etiketlendirme işlemi yine uzman veteriner ortopedist tarafından sadece X-ray görüntülerine bakılarak gerçekleştirilmiştir. Bu ayırım veteriner hekimlerce kallus dokusuna (yeni kemik dokusuna) bakılarak anlaşılmaktadır.

Bazı kaynaklar, kırık meydana geldikten 5-10 gün sonra kallus dokusunun oluşumunun başladığını belirtmektedir [105]. Şekil 3.6, kemiklerin iyileşme sürecini ayrıntılı olarak göstermektedir. Kallus oluşumunu ayırt edebilmek adına örnek olarak verilen röntgen görüntüleri ise Şekil 3.7'de görülebilir. Şekilden kırığın iyileşmesi devam ettikçe kallus dokusu oluşumunun giderek büyüdüğü gözlenebilmektedir [106,107].

Bilgi dahilinde yapılan araştırmalarda, bu alanın derin öğrenme tabanlı yöntemlerle henüz akademik çalışmalarda incelenmediği fark edilmiştir. İnsanların bu alanda çalışılmaması oldukça doğal olmasına karşın; sokak hayvanlarını içeren çoğu durumda, veteriner hekimler kırığın ne zaman meydana geldiğini bilemezler. Dolayısıyla, bu araştırma alanı hayvan tabanlı veri setleri üzerinde oldukça yararlı olacaktır.



Şekil 3.6. Bir kemiğin iyileşme süreci [105].



Şekil 3.7. Röntgen görüntülerinden bir kemiğin iyileşme süreci. a) yeni oluşan kırık, b) doku iyileşmesinin başlangıç aşaması, c) daha büyük kallus oluşumu. [106].

Çalışmada, 304'ü yeni kırık, 106'sı ise eski ve kaynamış kırık olmak üzere toplamda 410 adet X-ray görüntüsü kullanılmıştır. Çalışmada köpek ırkı, cinsiyeti, kemik çeşidi vb. parametreler dikkate alınmamıştır. Çalışmada, bir önceki çalışmadaki derin ağ yapıları kullanılmıştır.

Görüntülerin sınıflandırılması hem öğrenim aktarımı hem de bir makine öğrenmesi metodu olan SVM ile test edilmiş, sonuçlar Tablo 3.9'daki gibi olmuştur. Bu alt çalışmada, AlexNet'in en başarılı ağ yapısı olduğu görülmektedir. SVM ise %64,29'luk sınıflandırma başarısıyla daha geri planda kalmıştır.

Bir önceki çalışmadaki gibi, veri çoğaltma işlemi sonrasında tekrarlanan çalışma sonrası alınan çıktılar ise Tablo 3.10’da verilmiş; oluşturulan karmaşıklık matrisleri Tablo 3.11’deki gibi olmuştur. Elde edilen çıktılar, literatürde insan tabanlı araştırmalar da dahil olmak üzere bu konudaki eksikliğin giderilebileceğe işaret etmektedir.

Tablo 3.9. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	80,95
GoogLeNet	71,43
ResNet-50	73,81
SVM	64,29

Tablo 3.10. Çoğaltılmış veri kümesi ile ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	76,19
GoogLeNet	79,76
ResNet-50	83,33
SVM	59,52

Tablo 3.11. Ham ve çoğaltılmış veri kümeleri ile ağ mimarilerine göre oluşturulan karmaşıklık matrisleri

Mimari Yapı		Ham Veri Seti		Çoğaltılmış Veri Seti	
		Tahmini Değerler			
AlexNet	Gerçek Değerler	<i>Yeni Kırık</i>	<i>Eski Kırık</i>	<i>Yeni Kırık</i>	<i>Eski Kırık</i>
		18	3	34	8
		5	6	12	30
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,76	0,84	0,71	0,79
F1 Skoru: 0,80		F1 Skoru: 0,75			
GoogLeNet		17	4	36	6
		8	13	11	31
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,62	0,76	0,74	0,84
		F1 Skoru: 0,68		F1 Skoru: 0,79	
ResNet-50		18	3	40	2
		8	13	12	30
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,62	0,81	0,71	0,94
	F1 Skoru: 0,70		F1 Skoru: 0,81		
SVM	11	10	21	21	
	5	16	13	29	
	Hassasiyet	Kesinlik	Hassasiyet	Kesinlik	
	0,76	0,61	0,69	0,58	
	F1 Skoru: 0,68		F1 Skoru: 0,63		

3.4. Köpeklerdeki Uzun Kemik Kırıklarının Belirlenmesi

Önceki bölümlerde de anlatıldığı gibi bu araştırma, ortopedi alanına en faydalı çıktıyı üretecek alt çalışmalardan biridir. Bu konuda insan tabanlı veri setleri ile yapılan birçok çalışma mevcuttur. Çalışmaların başlıca örnekleri, raporun ilk bölümünde verilmiştir.

Çalışmada, 479'u kırık, 1549'u ise sağlam kemik olmak üzere toplamda 2028 adet X-ray görüntüsü kullanılmıştır. Çalışmada köpek ırkı, cinsiyeti, kemik çeşidi vb. parametreler dikkate alınmamıştır. Çalışmada, bir önceki çalışmadaki ağ yapıları ve sınıflandırıcısı kullanılmış, sonuçlar Tablo 3.12'de verilmiştir.

Tablo 3.12. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	82,29
GoogLeNet	88,54
ResNet-50	85,42
SVM	73,07

Son olarak gerçekleştirilen bu çalışmada ise, en başarılı ağ yapısının GoogLeNet olduğu görülmektedir. SVM ise kemik kırığını nitelendiren özneliklerin çıkartılmasında, derin mimariler kadar başarılı olamamıştır. Yapılan tüm çalışmalar karşılaştırıldığında, öğrenme aktarımı yönteminin veri setine uygun olduğunu ve bu sayede eğitim zamanından tasarruf etmek amacıyla rahatlıkla kullanılabileceği gözlemlenmiştir. Ayrıca günümüz literatüründe yeterince yer etmeyen bu araştırmaların, gelecek çalışmalar adına bir dönüm noktası oluşturacağı düşünülmektedir.

Önceki çalışmalardaki gibi, veri çoğaltma işlemi sonrasında tekrarlanan çalışma sonrası alınan çıktılar ise Tablo 3.13'te verilmiş; oluşturulan karmaşıklık matrisleri Tablo 3.14'teki gibi olmuştur.

Tablo 3.13. Çoğaltılmış veri kümesi ile ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	83,07
GoogLeNet	85,16
ResNet-50	88,54
SVM	68,26

Tablo 3.14. Ham ve çoğaltılmış veri kümeleri ile ağ mimarilerine göre oluşturulan karmaşıklık matrisleri

Mimari Yapı		Ham Veri Seti		Çoğaltılmış Veri Seti	
		Tahmini Değerler			
AlexNet	Gerçek Değerler	<i>Kırık</i>	<i>Sağlam</i>	<i>Kırık</i>	<i>Sağlam</i>
		82	14	166	26
		20	76	39	153
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,79	0,84	0,80	0,85
F1 Skoru: 0,81		F1 Skoru: 0,82			
GoogLeNet		85	11	151	41
		11	85	16	176
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,88	0,88	0,92	0,81
		F1 Skoru: 0,88		F1 Skoru: 0,86	
ResNet-50		80	16	158	34
		12	84	10	182
		Hassasiyet	Kesinlik	Hassasiyet	Kesinlik
		0,87	0,84	0,95	0,84
	F1 Skoru: 0,85		F1 Skoru: 0,89		
SVM	70	26	131	61	
	26	70	60	132	
	Hassasiyet	Kesinlik	Hassasiyet	Kesinlik	
	0,73	0,73	0,69	0,68	
	F1 Skoru: 0,73		F1 Skoru: 0,68		


3.4.1. Farklı veri çoğaltma yöntemlerinin kırık tespiti üzerindeki etkisinin incelenmesi

Bu alt çalışmada, temel veri setinden üç farklı geleneksel veri çoğaltma yöntemleri ile üç farklı veri seti oluşturulmuştur. Ardından üç yöntemin kırık tespitine olan etkileri ayrı ayrı incelenerek karşılaştırılmıştır.

Kullanılan geleneksel yöntemler aşağıda sıralanmıştır:

- a) Çevirme
- b) Rotasyon
- c) Kontrast değişimi

Tüm bu işlemlerin ardından; ana veri kümesinin boyutu 2028 (479 kırık, 1549 kırık olmayan kemik) adet görüntüden, her bir çoğaltılmış veri seti için 8108 (1916 kırık, 6196 kırık olmayan kemik) adet görüntüye dönüştürülmüştür. Her bir geleneksel yöntemde üç farklı ayar kullanılmıştır. Çevirme işlemi yatay, dikey ve hem yatay hem dikey olacak şekilde; rotasyon işlemi +30, -30 ve +45 derece olacak şekilde; kontrast limitleri ise Bölüm 2’de bahseldiği üzere üç farklı limit değerleri şeklinde görüntülere uygulanmıştır. Uygulama sonrası veri setinden elde edilen örnek görüntü çıktıları Şekil 3.8’de verilmiştir.



Şekil 3.8. Çoğaltma işleminden sonra veri setinden örnek görüntüler. a) dikey çevirme işlemi sonrası, b) 30 derece sola döndürülme sonrası, c) kontrast değişimi sonrası.

4:1 oranında rasgele olarak ayrılan eğitim ve test kümelerinden alınan çıktılar Tablo 3.15’te gösterilmiştir.

Tablo 3.15. Veri çoğaltma yöntemlerine göre sınıflandırma başarıları

Veri Seti	Sınıflandırma Başarısı (%)
Ham veri seti	77,57
Çevirme yöntemiyle çoklanmış veri seti	85,13
Rotasyon yöntemiyle çoklanmış veri seti	79,49
Kontrast değişimi yöntemiyle çoklanmış veri seti	89,34

Literatürde çok fazla veri çoğaltma yöntemi olmasına karşın, bu çalışmada başarıları ve uygulama kolaylığı açısından üç tanesi irdelenmiştir. Sonuçlara bakıldığında, ham verilere ait başarı oranının çoğaltılmış veri setleri sayesinde artırıldığı gözlemlenmiştir. Bu yöntemlerden en verimli olanının %90'a yakın tespit başarısı ile kontrast değişimi yöntemi olduğu göze çarpmaktadır.

Öteki taraftan, rotasyon metodunun başarı üzerinde pek bir etkiye sahip olduğu görülmemiştir. Bu sonucun altında yatan sebebin, rotasyon işleminin ardından meydana gelen boyut değişimi ile oluşan veri kaybı olduğu düşünülmektedir.


3.5. Köpeklerdeki Uzun Kemik Kırıklarının Sınıflandırılması

İnsan tabanlı veri setleri ile biyomedikal görüntü işleme alanında kırık tespiti, oldukça geniş bir uygulama alanı bulmaktadır; ancak bilgi dahilindeki literatür taramasında uzun kemiklerdeki kırık çeşitlerine dair herhangi bir sınıflandırma çalışmasına rastlanamamıştır. Bu sebeple, köpeklere ait X-ray görüntüleri kullanılarak, uzun kemiklerdeki kırıkların sınıflandırılması hedeflenmiştir. Kırık çeşidinin belirlenmesi, operasyon öncesinde ve operasyon sırasında; gerekli ameliyat materyallerinin temini ve ameliyatın zorluğu açısından ipucu vermesiyle veteriner hekimlere yardımcı olabilecek niteliktedir.

Tez çalışması kapsamında, kemik kırıkları üç kategoride değerlendirilmiştir:

1. Transversal kırık
2. Oblik (diyagonal) kırık
3. Çok parçalı kırık

Örnek olması adına, humerus kemiğine ait veri setinden rasgele seçilen üç farklı kırık çeşidi ile sağlam humerus görüntüsü Şekil 3.9’da gösterilmiştir.



Şekil 3.9. Veri setinde yer alan kırık çeşitlerine birer örnek. a) oblik, b) parçalı, c) transversal ve d) sağlam.

Dolayısıyla yapılan bu alt çalışmada X-ray görüntüleri, üç farklı kırık çeşidi ile sağlam etiketi olmak üzere dört sınıfta değerlendirilmiştir. Verileri sınıflandırma işleminde önceki çalışmalardaki başarılarından dolayı öğrenme aktarımı yöntemi tercih edilmiş ve ResNet-50, AlexNet ve GoogLeNet ağ yapıları kullanılmıştır.

Veri setinde kullanılan görüntü sayılarına Tablo 3.16’da yer verilirken elde edilen sınıflandırma başarıları Tablo 3.17’de özetlenmiştir.

Tablo 3.16. Alt çalışmada kullanılan veri seti

Etiket Adı	Görüntü Sayısı
Transversal kırığa sahip kemik	120
Oblik kırığa sahip kemik	88
Çok parçalı kırığa sahip kemik	154
Sağlam kemik	1549


Tablo 3.17. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
ResNet-50	55,56
AlexNet	44,44
GoogLeNet	52,78

Tablo 3.17'deki sonuçlara göre, sınıflandırma başarısının tatmin edici olmadığı; ancak ResNet-50 veya benzeri bir ağ yapısının kullanılarak yapılacak gelecek çalışmaların değerlendirilebileceği yorumu yapılabilir.

3.5.1. Köpeklerdeki Uzun Kemik Kırıklarının Sınıflandırılmasında Başarı Artırımına Yönelik Yapılan İncelemeler


Sınıflandırma başarısının artırımına yönelik yapılan ilk çalışma, bölütleme (segmentasyon) metotlarının incelenmesi olmuştur. Kümeleme (clustering) yapılarak bölütlenen veri seti, ResNet-50 mimarisi ile eğitilip SVM ile sınıflandırıldığında başarı oranı %44 olarak ölçülmüştür. Bu durum, bölütleme işleminin kırık sınıflandırma problemi üzerine negatif etkisi olduğunu göstermektedir. Kümeleme yapılarak bölütlenen veri setine ait örnek Şekil 3.10'da gösterilmiştir.




Şekil 3.10. Kümeleme yapılarak bölütlenen veri setine ait örnek bir görüntü.

Sınıflandırma başarısının artırımına yönelik yapılan diğer bir çalışma ise kenar algılama (edge detection) üzerinedir. Sobel, Prewitt ve Canny metotlarıyla yapılan karşılaştırmada; Sobel metotunun diğerlerine oranla çok az farkla daha başarılı olduğu görülmüş ve sadece Sobel ile kenar algılamanın yapıldığı sınıflandırmada başarının %46,67 olarak elde edildiği not edilmiştir. Şekil 3.11'de oblik kırık sınıfına ait bir görüntünün farklı kenar algılama yöntemleriyle alınan çıktı görüntülerine yer verilmiştir.

Bir başka araştırma konusu olarak ise Sobel metodu ile kenarların algılandığı çıktı görüntü matrisi üzerine gri dönüşümü yapılmış orijinal görüntü matrisi eklenmiş ve tekrar sınıflandırma işlemine tabi tutulmuştur. Bu şekilde oluşturulan veri seti ile yapılan sınıflandırma başarısı ise %51,85 olarak kaydedilmiştir. Örnek olmasına adına oblik kırık sınıfına ait bir görüntü Şekil 3.12'de verilmiştir.



Şekil 3.11. Farklı kenar algılama metotları kullanılarak alınan çıktılara örnekler. a) orijinal, b) sobel, c) canny ve d) prewitt.




Şekil 3.12. Sobel metodu ile gri dönüşümü yapılmış orijinal görüntü matrislerinin toplamına ait örnek çıktı.

Bu çıktılar değerlendirildiğinde, kenar algılama yöntemlerinin de çok farklı bir başarı sağlamadığı; ancak orijinal görüntü matrisi ile filtre çıktı matrisinin matematiksel olarak toplanmasıyla başarı artırımının mümkün olabileceği gelecek çalışmalarda daha detaylı incelenebilir.

Veri setinde yer alan her bir sınıf ele alındığında, özellikle oblik kırığa ait görüntü sayısının diğer sınıflara oranla daha az olduğu görülmektedir. Bu nedenle geleneksel yöntemlerden biri olan bulanıklaştırma metodu ile veri çoğaltma işlemi uygulanmış, derin ağların daha iyi öğrenmesi hedeflenmiştir. Bölüm 2’de anlatılan iki farklı görüntü parlaklık değişimi ile bir bulanıklaştırma işleminin görüntü sayılarının az olduğu kırık sınıflarına uygulanmasının ardından elde edilen görüntü sayıları Tablo 3.18’de verilmiştir. Çoğaltma işlemi sonucu elde edilen görüntüler ise Şekil 3.13’te örneklenmiştir.

Tablo 3.18. Görüntü çoğaltması sonucu alt çalışmada kullanılan veri seti

Etiket Adı	Görüntü Sayısı
Transversal kırığa sahip kemik	480
Oblik kırığa sahip kemik	352
Çok parçalı kırığa sahip kemik	616
Sağlam kemik	1549



Şekil 3.13. Çoğaltma işlemi sonucu örnek görüntüler. a) orijinal, b) parlaklık değişimi: I-50, c) parlaklık değişimi: I+50, d) sigma=1 iken elde edilen bulanık görüntü. (I: orijinal görüntü matrisi)

Bu veriler kullanılarak yine rastgele seçilen 0.8 oranlı eğitim seti ile ResNet-50 mimarisi eğitilmiş ve kalan test seti ile sınıflandırıcı test edildiğinde sınıflandırma başarısı %72,95'e çıkarılmıştır. Bu durum, veri çoğaltma işleminin sınıflandırıcı doğruluğu üzerine olumlu sonuçlar meydana getireceği sezgisini doğrumuştur.

3.6. Köpeklerdeki Uzun Kemiklere Göre Kırık Tespitinin Yapılması

İnsan tabanlı veri setleri ile kırık tespiti konusunda literatüre kazandırılmış fazlaca çalışmadan bahsedilmiştir; ancak yine bilgi dahilindeki bu çalışmalara kemik çeşidi incelemesi dahil edilmemiştir. Bu çalışmada problem sekiz sınıflı hale getirilmiştir.

Bu alt çalışmadaki sınıf bilgileri aşağıdaki gibidir:

1. Sağlam femur kemiği
2. Kırık femur kemiği
3. Sağlam humerus kemiği
4. Kırık humerus kemiği
5. Sağlam radius-ulna kemiği
6. Kırık radius-ulna kemiği
7. Sağlam tibia kemiği
8. Kırık tibia kemiği

Verileri sınıflandırma işleminde yine ResNet-50, AlexNet ve GoogleNet derin ağ yapıları kullanılmıştır. Bu alt çalışmada, kırığa sahip humerus görüntülerinin yeterli sayıda olmamasından dolayı, kırık humerus görüntüleri, -15 ve +15 derecelik rotasyon işlemlerinden geçirilerek toplam sayısı 133'e çıkarılmıştır.

Veri setinde kullanılan görüntü sayılarına Tablo 3.19'da yer verilirken elde edilen sınıflandırma başarıları Tablo 3.20'deki gibidir.

Tablo 3.20'de yer alan sonuçlara göre, en yüksek sınıflandırma başarısının, önceki çalışmada olduğu gibi yine ResNet-50 ağı ile elde edildiği gözlemlenmiştir. Ancak başarı oranlarının iyileştirilmesi, mimaride ya da veri setinde yapılacak modifikasyonlar ile mümkün olabileceği düşünülmektedir.

Tablo 3.19. Çalışmada kullanılan görüntü sayıları

Etiket Adı	Görüntü Sayısı
Sağlam femur kemiği	619
Kırık femur kemiği	174
Sağlam humerus kemiği	238
Kırık humerus kemiği	133
Sağlam radius-ulna kemiği	223
Kırık radius-ulna kemiği	116
Sağlam tibia kemiği	545
Kırık tibia kemiği	116

Tablo 3.20. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
ResNet-50	79,35
AlexNet	69,02
GoogLeNet	67,93

3.7. Köpeklerin Uzun Kemiklerinin ve Kırıklarının Sınıflandırılması

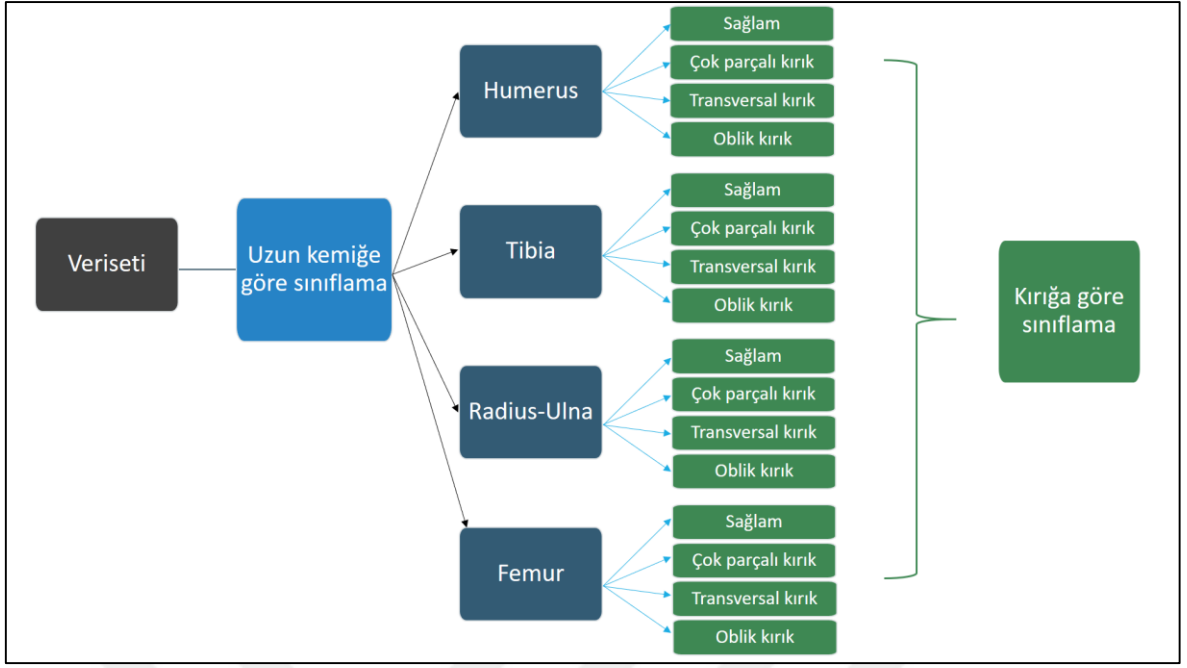
Doktora tezi kapsamında gerçekleştirilmesi planlanan ana çalışma, görüntülerden önce uzun kemiğin çeşidinin belirlenmesi, ardından kırığın varlığının saptanması ve var olması durumunda da kırığın cinsine göre sınıflandırılmasıdır. Çalışmaya ait bir akış diyagramı anlaşılabilirliği artırmak adına Şekil 3.14’te sunulmuştur.

Bu sınıflandırma probleminde 16 farklı sınıf etiketi vardır. Kemiklere ait her sınıfa ait görseller femur, humerus, radius-ulna ve tibia sırasıyla Şekil 3.15, Şekil 3.16, Şekil 3.17 ve Şekil 3.18’de sunularak tüm etiket bilgileri aşağıda listelenmiştir:


1. Sağlam femur kemiği
2. Parçalı kırığa sahip femur kemiği
3. Oblik kırığa sahip femur kemiği
4. Transversal kırığa sahip femur kemiği

5. Sađlam humerus kemiđi
6. Parçalı kırığa sahip humerus kemiđi
7. Oblik kırığa sahip humerus kemiđi
8. Transversal kırığa sahip humerus kemiđi
9. Sađlam radius-ulna kemiđi
10. Parçalı kırığa sahip radius-ulna kemiđi
11. Oblik kırığa sahip radius-ulna kemiđi
12. Transversal kırığa sahip radius-ulna kemiđi
13. Sađlam tibia kemiđi
14. Parçalı kırığa sahip tibia kemiđi
15. Oblik kırığa sahip tibia kemiđi
16. Transversal kırığa sahip tibia kemiđi


Tezin genel amacı dođrultusunda yapılan çalışmada kullanılan veri bilgileri ve öğrenme aktarımı yöntemi ile elde edilen başarılar sırasıyla Tablo 3.21 ve Tablo 3.22’de verilmiştir.



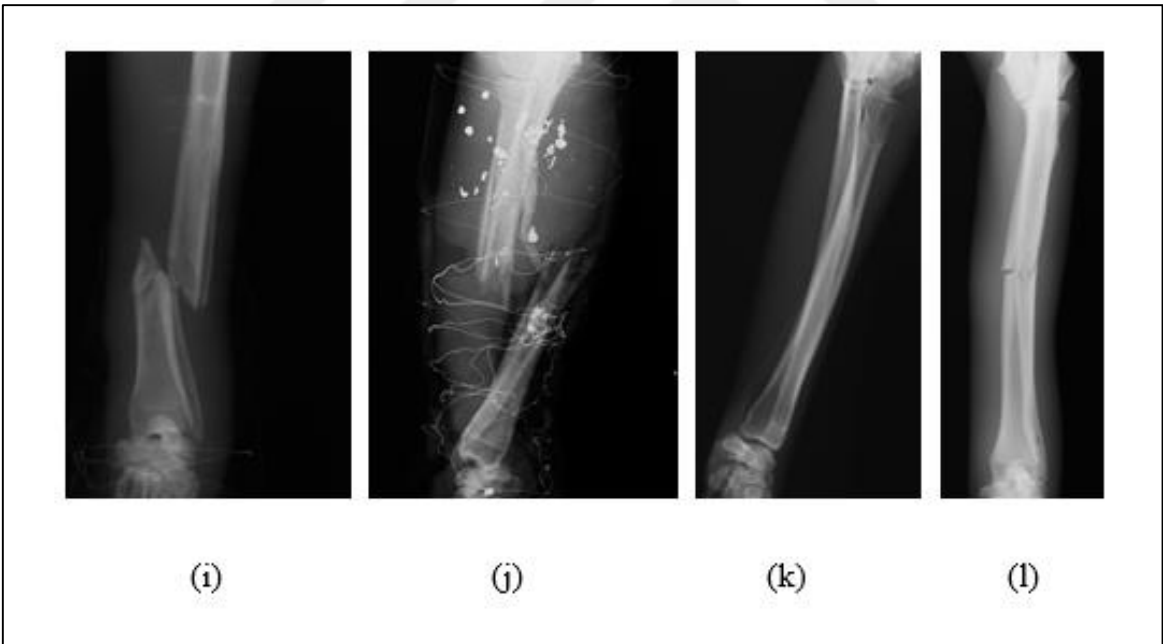
Şekil 3.14. Çalışmayı özetleyen akış diyagramı.




Şekil 3.15. Femur kemiğine ait alt sınıflar. a) oblik kırığa sahip femur kemiği, b) çok parçalı kırığa sahip femur kemiği, c) sağlam femur kemiği, d) transversal kırığa sahip femur kemiği.



Şekil 3.16. Humerus kemiğine ait alt sınıflar. a) oblik kırığa sahip humerus kemiği, b) çok parçalı kırığa sahip humerus kemiği, c) transversal kırığa sahip humerus kemiği, d) sağlam humerus kemiği.



Şekil 3.17. Radius-ulna kemiğine ait alt sınıflar. a) oblik kırığa sahip radius-ulna kemiği, b) çok parçalı kırığa sahip radius-ulna kemiği, c) sağlam radius-ulna kemiği, d) transversal kırığa sahip radius-ulna kemiği.



Şekil 3.18. Tibia kemiğine ait alt sınıflar. a) oblik kırığa sahip tibia kemiği, b) çok parçalı kırığa sahip tibia kemiği, c) sağlam tibia kemiği, d) transversal kırığa sahip tibia kemiği.

Tablo 3.21. Kemik ve kırık çeşitlerine göre toplam görüntü sayıları

Kemik Çeşidi	Sağlam Kemik	Oblik Kırık	Parçalı Kırık	Transversal Kırık
<i>Femur</i>	619	36	89	42
<i>Humerus</i>	238	23	11	14
<i>Radius-Ulna</i>	223	11	26	64
<i>Tibia</i>	545	30	36	40

Tablo 3.22. Ağ mimarilerine göre sınıflandırma başarıları

Mimari Yapı	Sınıflandırma Başarısı (%)
ResNet-50	46,88
GoogLeNet	40,62
AlexNet	40,62
VGG-16	34,38
VGG-19	31,25

Başarı oranları, veri setinin veya kullanılan yöntemlerin gözden geçirilmesi gerektiğini açıkça ortaya koymaktadır. Başarıyı düşüren temel sebebin, tezin önceki bölümlerinde de yer verilen kırık çeşidinin iyi saptanamamasından kaynaklı olduğu düşünülmektedir.

3.7.1. Köpeklerin Uzun Kemiklerinin ve Kırıklarının Sınıflandırma Başarısını Artırmaya Yönelik Yapılan Çalışmalar

a) Veri setinin genişletilmesi ve farklı derin ağ mimarilerinin etkilerinin incelenmesi

Bu problemde, sınıflandırma başarılarını yükseltmek adına, önceki alt çalışmalarda başarı vaat eden görüntü çoğaltma işlemleri uygulanmıştır.

Kırık olarak etiketlenen sınıf görüntüleri; üç farklı bulanıklaştırma ayarı ($\sigma=1$, $\sigma=1.25$ ve $\sigma=1.5$ değerleri) ve üç farklı çevirme ayarı (yatay, dikey ve hem yatay hem dikey olmak üzere) uygulanarak çoğaltılmıştır. Veri setindeki sağlam sınıflarında, diğer sınıflara oranla yeterli sayıda görüntü olduğu için çoğaltma işlemine gerek görülmemiştir.

Çoğaltma işleminin ardından 16 sınıfta sınıflandırma yapıldığında, alınan başarı oranları Tablo 3.23'te özetlenmiştir. Bu problem çözümü için daha fazla derin ağ mimari çeşidi incelenerek karşılaştırılmıştır.

Tablo 3.23. Çoğaltılmış veri seri ile 16 sınıf için yapılan sınıflandırmadaki başarı oranları

Mimari Yapı	Sınıflandırma Başarısı (%)
AlexNet	65,34
GoogleNet	64,49
ResNet-18	66,48
ResNet-50	72,44
ResNet-101	71,02
VGG-16	61,08
VGG-19	60,23
Inception-v3	80,68
DenseNet-201	73,58
Xception	73,86
InceptionResNet-v2	70,74

Tablo incelendiğinde, ResNet-50 mimarisinin diğer az sınıflı problemlerde olduğu gibi, 16 sınıf için de yine başarılı olduğu; ancak en yüksek başarının 80,68 doğruluk yüzdesi ile Inception-v3 mimarisinden elde edildiği göze çarpmaktadır. Mimariden elde edilen karmaşıklık matrisi Tablo 3.24'te verilmiştir. Bunun dışında DenseNet-201, 71 katman

barındıran Xception, ResNet-101 gibi oldukça çok katman barındıran derin ađ mimarilerinin daha başarılı öznitelik çıkardığı yorumu yapılabilir. AlexNet ile VGG ađlarının bu yapılara oranla çok az katman taşımakta ve bundan dolayı öznitelik çıkarma konusunda daha az etkiye sahip olduğu söylenebilir. Ayrıca, ham veri ile sınıflandırmaya oranla (Tablo 3.22) çođaltılmış veri ile sınıflandırma başarısı (Tablo 3.23) arasında oldukça fark olduğu gözlenmektedir. Bu gözlem, çođaltılmış veri seti ile derin mimarilerin daha iyi öğrendiđi ve neticesinde de verilerin daha iyi sınıflandırıldığı yorumunu getirmektedir.



Tablo 3.24. Inception-v3 mimarisinden elde edilen karmaşıklık matrisi

	Tahmini Değerler															
	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
Gerçek Değerler	15	5	2	0	0	0	0	0	0	0	0	0	0	0	0	0
	0	17	1	1	0	2	0	0	0	0	0	0	0	0	0	1
	0	1	19	0	0	1	0	0	1	0	0	0	0	0	0	0
	1	2	2	12	0	1	2	0	0	0	0	1	0	0	0	1
	0	0	0	0	19	0	1	0	0	0	0	1	1	0	0	0
	0	0	0	0	0	21	0	1	0	0	0	0	0	0	0	0
	0	0	0	0	0	1	20	0	0	0	0	1	0	0	0	0
	0	0	0	0	0	1	0	21	0	0	0	0	0	0	0	0
	0	0	0	0	0	1	0	0	18	1	0	1	0	0	0	1
	0	0	0	1	0	0	0	0	0	16	1	2	1	0	1	0
	0	0	0	0	0	1	0	0	0	1	20	0	0	0	0	0
	0	0	0	0	1	0	0	0	0	4	0	16	1	0	0	0
	0	0	0	0	0	0	0	0	0	0	0	0	19	1	1	1
	0	0	0	0	1	0	0	0	0	0	0	0	2	19	0	0
	0	0	1	0	1	0	0	1	0	0	1	0	1	0	15	2
	0	0	0	0	0	0	0	0	0	1	0	1	2	1	0	17

a) Oblik kırığa sahip femur kemiği,

b) Parçalı kırığa sahip femur kemiği,

c) Sağlam femur kemiği,

- d) Transversal kırığa sahip femur kemiği,
- e) Oblik kırığa sahip humerus kemiği,
- f) Parçalı kırığa sahip humerus kemiği,
- g) Transversal kırığa sahip humerus kemiği,
- h) Sağlam humerus kemiği,
- i) Oblik kırığa sahip radius-ulna kemiği,
- j) Parçalı kırığa sahip radius-ulna kemiği,
- k) Sağlam radius-ulna kemiği,
- l) Transversal kırığa sahip radius-ulna kemiği,
- m) Oblik kırığa sahip tibia kemiği,
- n) Parçalı kırığa sahip tibia kemiği,
- o) Sağlam tibia kemiği,
- p) Transversal kırığa sahip tibia kemiği.

b) Kaskat mimarilerin kullanılması

Sınıflandırma performansına olan etkisini irdelemek amacıyla, sınıflandırma işlemi parçalar halinde kaskat mimariler ile sınıflandırılmaya çalışılmıştır.

Uzun kemik kırıklarının sınıflandırması amacıyla kullanılan 1549 sağlam ve 479 kırık kemikten oluşan veri setinden elde edilen başarı oranları Tablo 3.12’de verilmiş, en başarılı ağ yapısının %88,54’lük performansı ile GoogLeNet yapısı olduğu görülmüştü. Buna karşın; çoğaltılmış veri setindeki kırık tespiti (Tablo 3.13) ile diğer alt problemlerin çözümünde ön plana çıkan mimari ResNet-50 olduğu önceki bölümlerde anlatılmıştı.

Kaskat sınıflandırma üzerine yapılan bu çalışmada, ilk olarak veri setinden kırık tespiti yapılmaya çalışılmış, ardından kırığın var olması durumunda kırığın çeşidi çıktı olarak vermeye çalışılmıştır. Bu amaçla ilk olarak ResNet-50 mimarisi ve akabinde SVM sınıflandırıcısı ile kırık olarak değerlendirilen görüntüler bilgisayarda bir klasörde toplanmıştır. Ardından bu dosya içinde kırık olarak değerlendirilen görüntüler, sahip olduğu kırık çeşidinin sınıflandırılabilmesi adına ikinci bir sınıflandırma işlemine tabi tutulmuştur.

İkinci katın derin ağ mimarisi seçiminde Tablo 3.23'ten yardım alınarak, en yüksek doğruluk oranına sahip mimari yapı olan Inception-v3 kullanılmıştır.

İlk katta yer alan sınıflandırma sonucu, ResNet-50 mimarisi %86,98'lik sınıflandırma performansı ile 958 adet görüntüyü (479 adet kırık ve veri setinden rastgele seçilen 479 adet sağlam kemiğe ait görüntü) Tablo 3.25'te verilen karmaşıklık matrisi ile sınıflandırmıştır.

Tablo 3.25. İlk kat için oluşturulan karmaşıklık matrisi

Gerçek Değerler	Tahmini Değerler	
	<i>Kırık</i>	<i>Sağlam</i>
	85	11
14	82	

Tablo 3.25'e bakılarak 99 adet görüntünün kırık olarak sınıflandırıldığı; ancak bu görüntülerden 85 adedinin doğru pozitif olduğu anlaşılmaktadır. Yani 14 adet görüntü sağlam kemik olmasına rağmen; sınıflandırıcı tarafından kırık kemik olarak sınıflandırılmıştır.

Doğru olarak sınıflandırılan 85 adet kırık kemik görüntüleri incelendiğinde, 37 tanesinin parçalı kırık; 28 tanesinin oblik kırık ve kalan 18 tanesinin transversal kırık olduğu saptanmıştır. Bu görüntüler, ikinci katta kullanılan Inception-v3 mimarisine girdi olarak verilmiş, sınıflandırma işleminin ardından elde edilen başarı oranı ise %57,64 olarak bulunmuştur. Kırık çeşidi düzeyinde problem detaylı incelendiğinde; özellikle transversal ve oblik kırıkların sınıflandırıcı tarafından yanlış tasniflendiği gözlenmiştir. Bu kırık çeşitlerinin birbirine benzemesi, kırık çeşitleri üzerinde yapılan tüm çalışmalardaki en büyük dezavantajlardan biri olmuştur.

4. TARTIŞMA VE YORUM

Doktora tezi kapsamında yapılan tüm çalışmalarda, günümüz literatürünün en sık kullanılan derin ağ mimarileri karşılaştırılmalı olarak incelenmiştir. Ayrıca literatürde kendine yeterince incelenme fırsatı bulamayan aşağıdaki konular, bu tez çalışmasına konu olmuştur:

- 1) Köpeklerdeki uzun kemiklerin sınıflandırılması
- 2) X-ray görüntülerinden köpeklerin yetişkinlik düzeyinin belirlenmesi
- 3) X-ray görüntülerinden uzun kemik kırıklarının zamana göre sınıflandırılması
- 4) Köpeklerdeki uzun kemik kırıklarının belirlenmesi
- 5) Köpeklerdeki uzun kemik kırıklarının sınıflandırılması
- 6) Köpeklerdeki uzun kemiklere göre kırık tespitinin yapılması
- 7) Köpeklerin uzun kemiklerinin ve kırıklarının sınıflandırılması

Derin ağ mimarilerin başarıları, kullanılan veri setine ve çalışmanın amacına bağlıdır. Bundan dolayı tez kapsamında yapılan çalışmalarda farklı ağ yapıları ile farklı başarımlar elde edilmiştir. Elde edilen çıktılar incelendiğinde; sınıfı niteleyen özniteliklerin ayırt ediciliği, sınıflandırıcı performansına doğrudan etki etmektedir. Örneğin kemik sınıflandırma çalışmasında, en yüksek doğruluğa sahip sınıflandırıcının AlexNet olmasının yanında, daha detaylı incelemelerin önemli rol oynadığı sınıflandırma problemlerinde ise Inception-v3 gibi çok katmanlı mimarilerin daha yüksek başarı oranlarına sahip olduğu görülmüştür.

Sıfırdan oluşturulan derin ağ mimarileri yüksek maliyet ve fazla zaman gerektirir. Oysaki öğrenim aktarımı yönteminin uygulanması daha hızlı sonuç verebilir. Bu avantaja ek olarak literatürdeki benzer çalışmalarda öğrenme aktarımı yönteminin daha başarılı sonuçlar verdiği vurgulanmıştır. Bu çalışmaların birinde mamografi görüntülerinde sıfırdan öğrenme ile öğrenme aktarımı yöntemleri karşılaştırılmış; alıcı işletim karakteristiği (Receiver Operating Characteristic, ROC) eğrisi altında kalan alanların önceden eğitilmiş model sayesinde artırıldığı bildirilmiştir [108]. Başka bir çalışmada, Tajbakhsh ve arkadaşları pulmoner emboli (akciğer atardamarının ani tıkanması) tespiti konusunda çalışmışlardır.

Çalışmalarında önceden eğitilmiş CNN yapısının ince ayar yapılarak, sıfırdan oluşturulmuş CNN yapısına oranla daha iyi performans verdiğini ortaya koymuşlardır [109]. Bu çalışmalar gibi, öğrenme aktarımının daha başarılı sonuçlar verdiğine dair benzer yayınlara rastlamak mümkündür. Tez kapsamında yapılan çalışmalarda da, iki yöntem birbiriyle kıyaslanmıştır. Kemik çeşidini sınıflandırma probleminde, sıfırdan oluşturulan ağı; öğrenme aktarımı yapılan ağlara oranla çok daha düşük doğruluk payı ile sınıflandırma yaptığı gözlenmiştir. Bu nedenle, tez kapsamında yapılan diğer alt çalışmalarda öğrenme aktarımı yöntemi tercih edilmiştir. Literatürde benzer çalışmalarda olduğu gibi, irdelenen çalışmalarda öğrenme aktarımı yöntemin etkili sonuçlar verdiği, Bölüm 3'te alınan çıktılar ile detaylı olarak gösterilmiştir.

Öğrenme aktarımı yöntemi her ne kadar başarılı sonuçlar ortaya koysa da sıfırdan meydana getirilen bir ağı daha yüksek sınıflandırma başarısı elde etmesi, tez kapsamında kullanılan veri seti için de mümkün olabilir. Çünkü sıfırdan oluşturulan bir ağ çok fazla parametreye sahiptir ve tüm bu parametrelerin en iyileme işlemi çok fazla efor ve zaman gerektirir. Özellikle hangi katmandan kaç tane ve hangi sırayla konulacağı gibi sorulara en iyi cevabı bulmak sıfırdan yaratılan ağlarda oldukça güç olmasına karşın; optimumun bulunması imkansız değildir.

En başarılı derin ağ mimarisinin, veri seti ve çalışmanın amacına göre farklılık göstermesi gibi, en başarılı sınıflandırıcı çeşidi de kullanılan verilere ve verilerin uygulama alanına bağlıdır. Tez kapsamında uzun kemiklerin ayrımını yapan ilk çalışmada gösterilmiştir ki; SVM sınıflandırıcısı, test edilen diğer sınıflandırıcılara oranla çok daha yüksek sınıflandırma başarısı elde etmiştir. Bu karşılaştırma çalışması SVM sınıflandırıcısının, tezin diğer alt çalışmalarında da kullanılabileceğini göstermiştir.

Yine literatür baz alındığında, derin ağ modellerinin güvenilirliğini artırmak amacıyla veri çoğaltma işlemleri uygulanmıştır. Özellikle görüntülerin kontrast limitlerinin değiştirilmesi ve bulanıklaştırılması işlemleri, oluşturulan veri setlerinde en etkili yöntemler olarak karşımıza çıkmaktadır. Çoğaltılmış veri seti ile elde edilen başarımlara dikkat edildiğinde, modellerin öznelik çıkarma başarılarının artırıldığı görülmüştür. Bunun yanı sıra eğitilen modellerin genelleştirme yapma yeteneklerinin geliştirildiği fark edilmiştir.

Her ne kadar hayvan tabanlı veri setleri ile yapılan benzer çalışmaların örneği az olsa da insan tabanlı veri setleri ile yapılan çalışmalarda alınan başarı oranlarının bazı

kıstaslardan dolayı çok yüksek olmadığından bahsedilmişti. Bu kıstasların başında veri setlerinde yeterli görüntü sayısının olmaması ve görüntülerin yüksek doğruluk ve titizlikle etiketlenilmemiş olması gelmektedir. Bu nedenle, doktora tezi doğrultusunda yapılan tüm çalışmaların özgün içerikte olduğu ve literatüre katkı sağladığı düşünülmektedir.



5. SONUÇ

Özellikle son yıllarda popüler hale gelen derin öğrenme metotları, pek çok uygulama alanı bulmasına karşın; hayvan tabanlı veri setlerini içeren problemlerde yeteri kadar tercih edilmemiştir. Bu tez çalışmasında, ilk olarak köpeklere ait X-ray görüntülerini barındıran geniş kapsamlı bir veri seti oluşturulmuştur. Veri seti, hayvan sağlığı açısından çok farklı yönleriyle ele alınmış ve uzman bir veteriner ortopedist tarafından dikkatlice etiketlenmiştir.

Hedeflenen problem çözümlerinde, farklı derin ağ mimarilerinin öğrenme aktarımı yöntemi ile karşılaştırılması yapılmıştır. Başarı oranlarını artırmak ve modellerin daha güvenilir olmasını sağlamak amacıyla veri çoğaltma işlemleri yapılmıştır. Problemlerin çözümlerinde kullanılan en başarılı ağ mimarileri ve çıktıları aşağıda listelenmiştir:

- 1) Köpeklerdeki uzun kemiklerin sınıflandırılması: AlexNet (%91,51)
- 2) X-ray görüntülerinden köpeklerin yetişkinlik düzeyinin belirlenmesi: ResNet-50 (%80,00)
- 3) X-ray görüntülerinden uzun kemik kırıklarının zamana göre sınıflandırılması: ResNet-50 (%83,33)
- 4) Köpeklerdeki uzun kemik kırıklarının belirlenmesi: GoogLeNet (%88,54)
- 5) Köpeklerdeki uzun kemik kırıklarının sınıflandırılması: ResNet-50 (%55,56)
- 6) Köpeklerdeki uzun kemiklere göre kırık tespitinin yapılması: ResNet-50 (%79,35)
- 7) Köpeklerin uzun kemiklerinin ve kırıklarının sınıflandırılması: Inception-v3 (%80,68)

Tez çalışmalarında alınan neticeler doğrultusunda, tezin iki temel önermesi vardır:

- 1) SVM sınıflandırıcısının diğer makine öğrenmesi algoritmalarına oranla derin ağ mimarileri ile daha iyi sınıflandırma yapabilmesi.
- 2) Öğrenme aktarımı metotunun, sıfırdan oluşturulan derin ağ mimarilerine oranla kısa sürede daha başarılı sonuçlar üretmesi.

Tez kapsamında yapılan tüm bu çalışmaların literatüre faydaları ise şu şekilde özetlenebilir:

1. Literatürde yeterince inceleme alanı bulamayan problemlerin çözümü, farklı derin ağ mimarileri kullanılarak karşılaştırılmalı olarak incelenmiştir.
2. Derin öğrenme yöntemleri, geniş kapsamlı veri setlerine ihtiyaç duyar; lakin araştırmacılar tarafından kolayca erişilebilen açık kaynaklı veri setleri oldukça sınırlıdır. Bu sebeple tez kapsamında oluşturulan veri seti, çalışmaların geliştirilmesi ve diğer araştırmacıların faydalanabilmesi adına çevrim içi erişilebilir bir platformda paylaşılmıştır.
3. Farklı bakış açıları ile ele alınmış hayvan sağlık problemlerinin, yapay zeka tabanlı çözüm önerileri sayesinde literatüre katkı sağlanmıştır.
4. Veteriner tıp ile mühendisliği bir araya getiren bu disiplinler arası doktora tez çalışmasında elde edilen sonuçlar, otomatik tanı sistemlerinde kullanılarak veteriner hekimlere yardımcı bir araç olarak kullanılabilir.

Bu tez çalışması ile gelecek çalışmalar için bir alt yapı oluşturulmuştur. Gelecek çalışmalarda veri setinde yer alan görüntülerin iyileştirilmesi, ağ yapılarının optimize edilmesi, probleme özgü derin ağ mimarilerinin geliştirilmesi gibi yaklaşımlar ele alınarak sınıflandırma performansına dair iyileştirmeler söz konusu olabilir.

KAYNAKLAR

- [1] A. Şeker, B. Diri, H. Hüseyin Balık, “Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme”, Gazi Mühendislik Bilimleri Dergisi, vol. 3, pp. 47-64, 2017.
- [2] A. Prason, K. Petersen, C. Igel, F. Lauze, E. Dam, M. Nielsen, “Deep Feature Learning for Knee Cartilage Segmentation Using a Triplanar Convolutional Neural Network”, MICCAI, pp. 246–253, 2013.
- [3] P. Sergio, P. Adriano, A. Carlos, “Brain Tumor Segmentation using Convolutional Neural Networks in MRI Images”, IEEE Transactions on Medical Imaging, pp. 1240-1251, 2016.
- [4] G. Urban, M. Bendszus, F. A. Hamprecht, J. Kleesiek, “Multi-modal Brain Tumor Segmentation using Deep Convolutional Neural Networks”, MICCAI BraTS Challenge Proceedings, pp. 31–35, 2014.
- [5] M. Adams, W. Chen, D. Holcendorf, M.W. McCusker, P. D. Howe, F. Gaillard, “Computer vs human: deep learning versus perceptual training for the detection of neck of femur fractures”, J Med Imaging Radiat Oncol; vol.63, pp. 27–32, 2019.
- [6] R. L. Galvez, E. P. Dadios, A. A. Bandala and R. R. P. Vicerra, "Threat Object Classification in X-ray Images Using Transfer Learning", 2018 IEEE 10th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), pp. 1-5, 2018.
- [7] R. Sa et al., "Intervertebral disc detection in X-ray images using faster R-CNN", 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 564-567, 2017.
- [8] L. Shen et al., "Multi-Domain Image Completion for Random Missing Input Data", in IEEE Transactions on Medical Imaging, vol. 40, no. 4, pp. 1113-1122, April 2021.
- [9] M. G. Linguraru et al., "Tumor Burden Analysis on Computed Tomography by Automated Liver and Tumor Segmentation", in IEEE Transactions on Medical Imaging, vol. 31, no. 10, pp. 1965-1976, Oct. 2012.

- [10] L. Mu et al., "Fine-Tuned Deep Convolutional Networks for the Detection of Femoral Neck Fractures on Pelvic Radiographs: A Multicenter Dataset Validation", in *IEEE Access*, vol. 9, pp. 78495-78503, 2021.
- [11] R. S. Upadhyay and P. Tanwar, "A Review on Bone Fracture Detection Techniques using Image Processing", 2019 International Conference on Intelligent Computing and Control Systems (ICCS), pp. 287-292, 2019.
- [12] R. Lindsey, A. Daluiski, S. Chopra, A. Lachapelle, M. Mozer, S. Sicular, D. Hanel, M. Gardner, A. Gupta, R. Hotchkiss, H. Potter, "Deep neural network improves fracture detection by clinicians", *Proc Natl Acad Sci USA*, vol. 115 pp. 11591–11596, 2018.
- [13] M. M. Najafabadi, F. Villanustre, T. M. Khoshgoftaar et al. "Deep learning applications and challenges in big data analytics", *Journal of Big Data* 2, 1, 2015.
- [14] H. El-Saadawy, M. Tantawi, H. A. Shedeed and M. F. Tolba, "A Hybrid Two-Stage GNG–Modified VGG Method for Bone X-Rays Classification and Abnormality Detection", in *IEEE Access*, vol. 9, pp. 76649-76661, 2021.
- [15] D. Marzorati, M. Sarti, L. Mainardi, A. Manzotti and P. Cerveri, "Deep 3D Convolutional Networks to Segment Bones Affected by Severe Osteoarthritis in CT Scans for PSI-Based Knee Surgical Planning", in *IEEE Access*, vol. 8, pp. 196394-196407, 2020.
- [16] B. Baydan, H. M. Ünver, "Detection of tibial fractures in cats and dogs with deep learning", *Ankara Üniversitesi Veteriner Fakültesi Dergisi*, vol. 68, pp. 283-290. 2021.
- [17] B. Baydan, H. M. Ünver: "Dataset creation and SSD mobilenet V2 performance evaluation for dog tibia fracture detection", II. International Ankara Congress of Scientific Research, Ankara, Turkey, 6-8 March, 2020.
- [18] B. Baydan, H. M. Ünver, N. Barışçı, "Determining the Location of Tibial Fracture of Dog and Cat Using Hybridized Mask R-CNN Architecture", *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, vol. 27, 3, pp. 347 – 353, 2021.
- [19] Ümit KAYA, "Kırıkların Sınıflandırılması," [PowerPoint sunumu]. Ankara Üniversitesi Veteriner Fakültesi Ortopedi ve Travmatoloji Bilim Dalı. <https://acikders.ankara.edu.tr/course/view.php?id=5663>.

- [20] Li Deng and Dong Yu, "Deep Learning: Methods and Applications", *Found. Trends Signal Process.* 7, 3–4, 197–387, 2014.
- [21] R. Zemouri, N. Zerhouni, D. Racoceanu, "Deep Learning in the Biomedical Applications: Recent and Future Status", *Applied Sciences*, 9 (8), 2019.
- [22] X. Du, S. Yin, R. Tang, Y. Liu, Y. Song, Y. Zhang, H. Liu, S. Li, "Segmentation and visualization of left atrium through a unified deep learning framework", *Int J CARS*, vol.15, pp. 589–600, 2020.
- [23] Johannes Kvam, Lars Erik Gangsei, Jørgen Kongsro, Anne H Schistad Solberg, "The use of deep learning to automate the segmentation of the skeleton from CT volumes of pigs", *Translational Animal Science*, vol. 2, pp. 324–335, 2018.
- [24] F. J. McEvoy, J. M. Amigo, "Using machine learning to classify image features from canine pelvic radiographs: evaluation of partial least squares discriminant analysis and artificial neural network models," *Veterinary Radiology & Ultrasound*, vol. 54 (2), pp. 122-126, 2013.
- [25] Krunoslav Vinicki, Pierluigi Ferrari, Maja Belic, Romana Turk, "Using Convolutional Neural Networks for Determining Reticulocyte Percentage in Cats", Mar. 2018.
- [26] T. Banzato, M. Bernardini, G. B. Cherubini, A. Zotti, "A methodological approach for deep learning to distinguish between meningiomas and gliomas on canine MR-images", *BMC Vet Res.* Oct 22, 14(1):317, 2018.
- [27] P. Arsomngern, N. Numcharoenpinij, J. Piriataravet, W. Teerapan, W. Hinthong and P. Phunchongharn, "Computer-Aided Diagnosis for Lung Lesion in Companion Animals from X-ray Images Using Deep Learning Techniques," 2019 IEEE 10th International Conference on Awareness Science and Technology (iCAST), Morioka, Japan, pp. 1-6, 2019.
- [28] X. Huang, X. Li and Z. Hu, "Cow tail detection method for body condition score using Faster R-CNN", 2019 IEEE International Conference on Unmanned Systems and Artificial Intelligence (ICUSAI), Xi'an, China, pp. 347-351, 2019.

- [29] Zbigniew A. Starosolski, Herman Kan, and Ananth Annapragada "CNN-based detection of distal tibial fractures in radiographic images in the setting of open growth plates", Proc. SPIE 11314, Medical Imaging 2020: Computer-Aided Diagnosis, 2020.
- [30] V. Couteaux, S. Si-Mohamed, O. Nempont et al. "Automatic knee meniscus tear detection and orientation classification with Mask-RCNN", Diagn Interv Imaging, vol. 100, pp. 235-242, 2019.
- [31] M. Gopalakrishnan, J. Sheng, M. Valesani, "Automated Detection of Breaks and Fractures in X-Ray Bone Images," 2019.
- [32] C. Chin, Y. Lin and Y. Liu, "Various Types Fracture Labeling in Bone Radiographs Using Modified AC-GAN," 2019 International Conference on Technologies and Applications of Artificial Intelligence (TAAI), Kaohsiung, Taiwan, pp. 1-6, 2019.
- [33] S. Beyaz, Salih, K. Açıcı, E. Sümer, "Derin Öğrenme ve Genetik Algoritma Yaklaşımları Kullanılarak X-Ray Görüntülerinde Femur Boyun Kırığı Tespiti," Uluslararası Sağlıkta Yapay Zeka Kongresi, İzmir, Türkiye, 2020.
- [34] D. H. Kim, T. MacKinnon, "Artificial intelligence in fracture detection: Transfer learning from deep convolutional neural networks", Clin. Radiol., vol. 73, pp. 439–445, 2018.
- [35] Y. Chen, "Classification of Atypical Femur Fracture with Deep Neural Networks", KTH University: Stockholm Sweden, 2019.
- [36] Wang et al., "Skeletal Maturity Recognition Using a Fully Automated System with Convolutional Neural Networks", IEEE Access, vol. 6, pp. 29979-29993, 2018.
- [37] J. C. Castillo, Y. Tong, J. Zhao and F. Zhu, "RSNA Bone-age Detection using Transfer Learning and Attention Mapping", 2018.
- [38] Dogs Skeletal System, <https://vet-dr.weebly.com/small-animals2.html>, erişim: 20.11.2021, 20.58.
- [39] Raúl de la Fuente Lopes, "Wild Data Part 1: Augmentation", <https://bit.ly/3GU0Uq9>, erişim: 19.04.2021, 18.56.

- [40] Luis Perez, Jason Wang, “The Effectiveness of Data Augmentation in Image Classification using Deep Learning”, *Computer Vision and Pattern Recognition*, 2017.
- [41] Z. Hussain, F. Gimenez, D. Yi, D. Rubin. “Differential Data Augmentation Techniques for Medical Imaging Classification Tasks,” *AMIA Annu Symp Proc.*, pp. 979-984, 2018.
- [42] S. Jia, P. Wang, P. Jia, S. Hu. “Research on data augmentation for image classification based on convolutional neural networks”, *Chinese automation congress*, pp. 4165–4170, 2017.
- [43] Shunjiro Noguchi Mizuho Nishio Masahiro Yakami Keita Nakagomi Kaori Togashi, “Bone segmentation on whole-body CT using convolutional neural network with novel data augmentation techniques”, *Computers in Biology and Medicine*, vol. 121, 2020.
- [44] A. Hernández-García, P. König, “Further Advantages of Data Augmentation on Convolutional Neural Networks”, *Artificial Neural Networks and Machine Learning ICANN 2018. Lecture Notes in Computer Science*, vol 11139. Springer, Cham., 2018.
- [45] Sajjad M. et. al. “Multi-grade brain tumor classification using deep CNN with extensive data augmentation”, *Journal of Computational Science*, vol. 30, pp.174-182, 2019.
- [46] B. Abdollahi, N. Tomita, S. Hassanpour, “Data Augmentation in Training Deep Learning Models for Medical Image Analysis”, *Deep Learners and Deep Learner Descriptors for Medical Applications. Intelligent Systems Reference Library*, vol 186. Springer, Cham.
- [47] Siddharth Misra, Yaokun Wu, “Machine learning assisted segmentation of scanning electron microscopy images of organic-rich shales with feature extraction and feature ranking”, in *Machine Learning for Subsurface Characterization*, 2020.
- [48] “Why you need a dedicated library for image augmentation”, <https://bit.ly/3oYoXOx>, erişim: 11.12.21, 21.55.
- [49] K. Zhang, Z. Zhang, Z. Li and Y. Qiao, "Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks", in *IEEE Signal Processing Letters*, vol. 23, no. 10, pp. 1499-1503, Oct. 2016.

- [50] D. Maltonl, D. Maio and A. K. Jain, "Salil prabhakar", Handbook of fingerprint recognition, pp. 171-172, 2009.
- [51] Sivaanandh M, Sai Surya and G. Priyanka, "Hand Written Indian Numeral Character Recognition using Deep Learning approaches", 2018 International Conference on Recent Innovations in Electrical, Electronics & Communication Engineering (ICRIEECE), pp. 1301-1304, 2018.
- [52] R. R. Subramanian, C. S. Niharika, D. U. Rani, P. Pavani and K. P. L. Syamala, "Design and Evaluation of a Deep Learning Algorithm for Emotion Recognition", 2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS), pp. 984-988, 2021.
- [53] Y. A. Kara, Ö. K. Uçarer and B. Gündoğdu, "Automatic Warship Recognition System: Dataset, Feature Representation and Classification Analysis", 2019 27th Signal Processing and Communications Applications Conference (SIU), pp. 1-4, 2019.
- [54] B. Wang, Y. Zhou, H. Zhang and N. Wang, "An Aircraft Target Detection Method Based on Regional Convolutional Neural Network for Remote Sensing Images", 2019 IEEE 9th International Conference on Electronics Information and Emergency Communication (ICEIEC), pp. 474-478, 2019.
- [55] R. M. James and A. Sunyoto, "Detection Of CT - Scan Lungs COVID-19 Image Using Convolutional Neural Network And CLAHE", 2020 3rd International Conference on Information and Communications Technology (ICOIACT), pp. 302-307, 2020.
- [56] Di Guan, "Classical Architectures in CNN", <https://guandi1995.github.io/Classical-CNN-architecture>, erişim: 04.12.2021, 18.08.
- [57] Y. LeCun et al., "Backpropagation Applied to Handwritten Zip Code Recognition", Neural Comput., vol. 1, no. 4, pp. 541–551, Dec. 1989.
- [58] Oğuzhan Öztaş, "Görüntü İşleme Teknikleri – 1," [PowerPoint sunumu]. İstanbul Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, <http://www.oguzhanoztas.com/gi/ders1.pdf>.

- [59] Krut Patel, “Convolutional Neural Networks — A Beginner’s Guide”, <https://bit.ly/3GXpYMX>, erişim: 24.12.2021, 23.20.
- [60] Ayyüce Kızrak, “Derin Öğrenme İçin Aktivasyon Fonksiyonlarının Karşılaştırılması”, <https://bit.ly/3JzH2ui>, erişim: 15.12.21, 20.00.
- [61] Sema Candemir, Xuan V. Nguyen, Les R. Folio, and Luciano M. Prevedello, “Training Strategies for Radiology Deep Learning Models in Data-limited Scenarios,” *Radiology: Artificial Intelligence*, 3:6, 2021.
- [62] Nova Research Lab., “Öğrenme Aktarımı/ Transfer Learning”, <https://bit.ly/3JzHMzA>, erişim: 23.01.22, 18.30.
- [63] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks”, in *Advances in neural information processing systems*, pp. 1097–1105, 2012.
- [64] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, "Going deeper with convolutions", 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, pp. 1-9, 2015.
- [65] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Deep residual learning for image recognition", In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778, 2016.
- [66] K. Simonyan, A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, conference paper at ICLR 2015.
- [67] Mahdianpari, Masoud & Salehi, Bahram & Rezaee, Mohammad & Mohammadimanesh, Fariba & Zhang, Yun, “Very Deep Convolutional Neural Networks for Complex Land Cover Mapping Using Multispectral Remote Sensing Imagery”, *Remote Sensing*, 10, 1119, 2018.
- [68] G. Huang, Z. Liu and L. van der Maaten, “Densely Connected Convolutional Networks”, 2018.

- [69] Jianming Zhang , Chaoquan Lu , Xudong Li , Hye-Jin Kim, Jin Wang, “A full convolutional network based on DenseNet for remote sensing scene classification”, [J]. *Mathematical Biosciences and Engineering*, vol. 16, pp. 3345-3367, 2019.
- [70] Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, Alex Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning”, Feb 2016.
- [71] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, Zbigniew Wojna. “Rethinking the Inception Architecture for Computer Vision”, Dec. 2015.
- [72] François Chollet, “Xception: Deep Learning with Depthwise Separable Convolutions”, 2017.
- [73] Leonardo, Matheus & Carvalho, Tiago & Rezende, Edmar & Zucchi, Roberto & Faria, Fabio, Deep Feature-Based Classifiers for Fruit Fly Identification (Diptera: Tephritidae). 41-47. 10.1109/SIBGRAPI.2018.00012, 2018.
- [74] Cortes, C., Vapnik, V. Support-vector networks. *Mach Learn* vol. 20, pp. 273–297, 1995.
- [75] E. Kaan Ulgen, “Makine Öğrenimi Bölüm-4 (Destek Vektör Makineleri)”, <https://bit.ly/36h0MV7>, erişim: 24.12.2021, 23.50.
- [76] Tomonori Kikuchi, Shigeo Abe, “Comparison between error correcting output codes and fuzzy support vector machines”, *Pattern Recognition Letters*, vol. 26, pp. 1937-1945, 2005.
- [77] Syarif, Iwan, Prugel-Bennett, A. & Wills, Gary. “SVM Parameter Optimization using Grid Search and Genetic Algorithm to Improve Classification Performance”, *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol.14, 2016.
- [78] Mitchell, T., “Machine Learning”, McGraw Hill, New York, 1997.
- [79] E. Eşme, B. Karlik, “Comparison Supervised Learning Algorithms for Gases/Odors Identification”, *Intellectual Systems of Decision-Making and Problems of Computational Intelligence (ISDMCI'14)*, Ukraine, 2014.

- [80] A. E. Taşçı, A. Onan, “K En Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi”, Akademik Bilişim, pp. 1 – 8, 2016.
- [81] Ruihu Wang, “AdaBoost for Feature Selection, Classification and Its Relation with SVM, A Review”, Physics Procedia, vol. 25, pp. 800-807, 2012.
- [82] Y. Freund, R. Shapire, “A decision-theoretic generalization of on-line learning and application to boosting”, Proceedings of the Second European Conference on Computational Learning Theory, pp. 23-27, 1995.
- [83] Kadir Güzel, “Boosting Nedir? Adım Adım AdaBoost Algoritması”, <https://bit.ly/36boodJ>, erişim: 23.01.2022, 23.00.
- [84] A. Stuart, K. Ord, Kendall's Advanced Theory of Statistics: Volume I—Distribution Theory, Edward Arnold, 1994.
- [85] P. Kaviani, S. Dhotre, “Short Survey on Naive Bayes Algorithm,” International Journal of Advance Research in Computer Science and Management, vol. 4, 2017.
- [86] Burhan Bilen, “Karışıklık Matrisi (Confusion Matrix)”, <https://bit.ly/3gYPXt3>, erişim: 11.10.2021, 19.59.
- [87] Stock Medical and Veterinary Illustrations, “Drawing of dog skeletal system,” <https://bit.ly/3BvBi1L>, erişim: 19.10.2020, 19.01.
- [88] R. Yamashita, M. Nishio, R. K. G. Do, et al., “Convolutional neural networks: an overview and application in radiology”, Insights Imaging, vol. 9, pp. 611–629, 2018.
- [89] S. Abdulghani, A. Fadhil, S. S. Gültekin, "Transfer Learning using Alexnet with Support Vector Machine for Breast Cancer Detection", Avrupa Bilim ve Teknoloji Dergisi, pp. 423-430, 2020.
- [90] L. Torrey and J. Shavlik, “Transfer Learning,” Handbook of Research on Machine Learning Applications, IGI Global, 2009.
- [91] N. Tajbakhsh et al., “Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning”, IEEE Transactions on Medical Imaging, vol. 35, 2016.

- [92] Nitesh Pradhan et al., “Classification of Human Bones Using Deep Convolutional Neural Network”, IOP Conference Series: Materials Science and Engineering, 2019.
- [93] S.H. Kilborn, G. Trudel, H. Uthoff, “Review of growth plate closure compared with age at sexual maturity and lifespan in laboratory animals”, *Contemp Top Lab Anim Sci.*, 41(5):21-6, Sep 2002.
- [94] Amy Pishner, “The greatest argument against early sterilization is the orthopedic repercussions”, <https://bit.ly/3s0HRqg>, erişim: 28.01.2021, 19.32.
- [95] Ginetta George, “How old should my dog be to canicross?”, <https://bit.ly/3GXjPjZ>, erişim: 28.01.2021, 20.11.
- [96] L. Olivares, L. León and M. Fragoso, “Skeletal age prediction model from percentage of adult height in children and adolescents”, *Scientific reports*, vol.10, 2020.
- [97] J. E O’Connor, J. Coyle, C. Bogue, LD. Spence, J. Last, “Age prediction formula from radiographic assessment of skeletal maturation at the knee in an Irish population”, *Forensic Sci Int.* 234:188, 2014.
- [98] D. L. Duren, R.W. Nahhas, R.J. Sherwood, “Do Secular Trends in Skeletal Maturity Occur Equally in Both Sexes”, *Clin Orthop.* 473 (8):2559–67, 2015.
- [99] M. A. Zulkifley, S. R. Abdani, N. H. Zulkifley, “Automated Bone Age Assessment with Image Registration Using Hand X-ray Images”, *Appl. Sci.*, 10, 7233, 2020.
- [100] H. Lee, S. Tajmir, J. Lee, M. Zissen, B. Yeshiwas, T. Alkasab, G. Choy, S. Do, “Fully Automated Deep Learning System for Bone Age Assessment”, *Journal of digital imaging*, vol. 30, 2017.
- [101] X. Pan, Y. Zhao, H. Chen, D. Wei, C. Zhao, Z. Wei, “Fully Automated Bone Age Assessment on Large-Scale Hand X-Ray Dataset”, *International Journal of Biomedical Imaging*, 1-12, 2020.
- [102] Richard Bednarski, Kurt Grimm, Ralph Harvey, Victoria M. Lukasik, W. Sean Penn, Brett Sargent, Kim Spelts; AAHA Anesthesia Guidelines for Dogs and Cats. *J Am Anim Hosp Assoc* 1; 47 (6): 377–385, November 2011.

- [103] Haeberli, P., Voorhies, D., “Image processing by linear interpolation and extrapolation”, IRIS Universe Magazine 28, 8–9, 1994.
- [104] David J. Pogue, Steven F. Viegas, Rita M. Patterson, Pamela D. Peterson, David K. Jenkins, Timothy D. Sweo, James A. Hokanson, “Effects of distal radius fracture malunion on wrist joint mechanics”, The Journal of Hand Surgery, vol. 15, Issue 5, pp. 721-727, 1990.
- [105] Wang, Wenhao & Yeung, Kelvin, “Bone grafts and biomaterials substitutes for bone defect repair: A review”, Bioactive Materials, 2017.
- [106] Meredith Kapler and David Dycus “Part 2: Selection of Fixation Technique & External Coaptation”, A Practitioner’s Guide to Fracture Management, September/October, 2015.
- [107] T. Einhorn, L. Gerstenfeld, “Fracture healing: mechanisms and interventions”, Nat Rev Rheumatol 11, 45–54, 2015.
- [108] G. Carneiro, J. Nascimento, A. P. Bradley, “Unregistered multi-view mammogram analysis with pre-trained deep learning models”, Navab N, Hornegger J, Wells W, Frangi A, eds. Medical image computing and computer-assisted intervention, vol. 9351, Lecture notes in computer science. Cham, Switzerland: Springer, 652–660, 2015.
- [109] N. Tajbakhsh, J. Y. Shin, S. R. Gurudu, et al., “Convolutional neural networks for medical image analysis: full training or fine tuning?” IEEE Trans Med Imaging, vol. 35, pp. 1299–1312, 2016.

EKLER

EK 1: Veri Seti Kullanımı ve Paylaşımı için İzin Belgesi





T.C.
ANKARA BÜYÜKŞEHİR BELEDİYE BAŞKANLIĞI
Sağlık İşleri Dairesi Başkanlığı
Veteriner İşleri Şube Müdürlüğü

Sayı : E-17993134-900-322770

22.12.2021

Konu : X-Ray Görüntüleri Veri Seti

SAYIN SELDA GÜNEY
DR.ÖĞR.ÜYESİ
BAŞKENT ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜNE

İlgide kayıtlı talebinizde Başkent Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Doktora Programında öğrenim görmekte olan Gülnur Begüm ERGÜN' ün doktora tezi çalışması kapsamında, köpeklere ait X-Ray görüntülerini içeren bir veri setinin akademik çalışmalar amacıyla kullanımını ve paylaşılmasını talep etmekteyiz.

İş bu talebiniz doğrultusunda Sincan Geçici Hayvan Bakımevi ve Rehabilitasyon Merkezimizdeki envanterimizde daha evvelden çekilmiş olan görüntülerden personelimiz eşliğinde destek alabileceğiniz hususunda;

Bilgilerinizi ve gereğini rica ederim.

Seyfettin ASLAN
Sağlık İşleri Dairesi Başkanı

Bu belge, güvenli elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : DAT4-AVRM-0AEO

Belge Doğrulama Adresi : <https://ebyssorgu.ankara.bel.tr>

Adres: Hipodrom Cad. No:5 Yenimahalle / ANKARA

Telefon No : (0312) 507 22 51

Fax No : (0312) 507 22 61

İnternet Adresi : <http://www.ankara.bel.tr/> e-Posta :

Keş Adresi : ankarabuyuksehirbelediyesi@hs01.kep.tr

Bilgi İçin :Filiz DOĞAN

Şef

Dahili No:5074755

