

KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
DOKTORA TEZİ



DERİN ÖĞRENME İLE KÖPEK VE KEDİ TİBİA KEMİKLERİ ÜZERİNDEKİ  
KIRIKLARIN TESPİTİ VE SINIFLANDIRMASI

Berker BAYDAN

EYLÜL 2021

**Bilgisayar Mühendisliği Anabilim Dalında** Berker BAYDAN tarafından Derin Öğrenme ile Köpek ve Kedi Tibia Kemikleri Üzerindeki Kırıkların Tespiti ve Sınıflandırması adlı Doktora Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Doç. Dr. Atilla ERGÜZEN  
Anabilim Dalı Başkanı

Bu tezi okuduğumu ve tezin **Doktora Tezi** olarak bütün gereklilikleri yerine getirdiğini onaylarım.

Doç. Dr. Halil Murat ÜNVER  
Danışman

Jüri Üyeleri

Başkan	: Prof. Dr. Necaattin BARIŞCI	_____
Üye (Danışman)	: Doç. Dr. Halil Murat ÜNVER	_____
Üye	: Prof. Dr. Celal İZCİ	_____
Üye	: Doç. Dr. Atilla ERGÜZEN	_____
Üye	: Dr. Öğr. Üyesi Erdal ERDAL	_____

.../.../.....

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Doktora derecesini onaylamıştır.

Prof. Dr. Recep ÇALIN  
Fen Bilimleri Enstitüsü Müdürü



**Aileme**

## ÖZET

### DERİN ÖĞRENME İLE KÖPEK VE KEDİ TİBİA KEMİKLERİ ÜZERİNDEKİ KIRIKLARIN TESPİTİ VE SINIFLANDIRMASI

BAYDAN, Berker

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi

Danışman: Doç. Dr. Halil Murat ÜNVER

Eylül 2021, 96 sayfa

Tibia kırığı veteriner hekimlikte özellikle kedi ve köpeklerde çok sık rastlanan kırık şeklidir. Tibiadaki kırığın daha doğru, hızlı ve güvenli bir şekilde teşhis edilmesi hem klinisyen hem de hayvan sağlığı için oldukça önemlidir. Bu sebepten bilgisayar destekli sistemler ile otomatik tespit etme yöntemleri önemli hale gelmiştir. Derin öğrenme gibi en gelişmiş bilgisayar destekli yöntemler kullanılarak insanlarda kırık teşhisi yapılmaktadır. Bu çalışmanın amacı iki kısımdan oluşmaktadır. Birincisi derin öğrenme yöntemlerinden Mask R-CNN ve SSD'yi kullanarak kedilerin ve köpeklerin bütün/kısmi dijital görüntüleri üzerinde tibiayı (kırık/kırık değil) sınıflandırmak ve kırık olarak tespit edilmiş tibialar üzerinde kırığın yerini belirlemektir. İkincisi öznetelik çıkarım için kullanılan klasik Mask R-CNN mimarisinin omurgasında yer alan bölümü hibrit yapıya dönüştürüp kedi ve köpeklerdeki tibia kırığının tespit performansını yükseltmektir. Üniversite ve kurumlardan 1488 adet köpek ve kedi dijital görüntü elde edilmiştir. Buna istinaden tibia kırığı tespiti için dört farklı çalışma yapıldı. Birinci çalışmanın birinci fazında, kırık ve sağlam tibia sınıflandırılması otomatik şekilde Mask R-CNN kullanılarak yapıldı. İlk fazdan elde edilen kırık tibiadaki kırık yeri Mask R-CNN kullanılarak ikinci fazda belirlendi. İkinci çalışmada, kırık yeri doğrudan lokalize edilme işlemi için Mask R-CNN kullanıldı. Üçüncü

çalışmada birinci çalışmanın birinci fazından elde edilen kırık tibia'daki kırık yeri SSD kullanılarak lokalize edildi. Dördüncü çalışmada Mask R-CNN çatısında kullanılan orjinal omurga yapısını hibrit hale getirerek köpek ve kedi tibia kırıklarındaki kırık bölgelerinin tespiti yapıldı. Birinci çalışmanın birinci faz doğruluk ve F1 skor değerleri sırasıyla %74 ve %85, birinci çalışmanın ikinci faz F1 skor değeri ise %84,5 olarak bulundu. İkinci çalışmanın doğruluk ve F1 skor değerleri sırasıyla %52,1 ve %68,5 olarak bulundu. Üçüncü çalışmanın F1 skor değeri ise %46,2 olarak bulundu. Dördüncü çalışmanın F1 skor değeri %85.8 olarak bulundu. Araştırmada yapılan çalışmanın sonuçlarına göre hibrit sistemin orjinal Mask R-CNN mimarisine göre daha başarılı tespitler yaparak hayvan sağlığının korunması açısından faydalı olacağını ve bu tip akıllı sistemler yardımıyla kırık teşhisinin yaygınlaştırılmasının hayvan refahı yönünden de yararlı olacağını gösterdi.

**Anahtar kelimeler:** Derin öğrenme, Hibrit, Kedi, Kırık, Köpek, Mask R-CNN, Tibia

## ABSTRACT

### DETECTION AND CLASSIFICATION OF FRACTURES ON DOG AND CAT TIBIA BONES WITH DEEP LEARNING

BAYDAN, Berker

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, Ph. D. Thesis

Supervisor: Assoc. Prof. Halil Murat ÜNVER

September 2021, 96 pages

Tibia fracture is a very common form of fracture in veterinary medicine, especially in cats and dogs. It is very important for both the clinician and the animal health to diagnose the fracture in the tibia more accurately, quickly and safely. For this reason, computer aided systems and automatic detection methods have become important. Fractures are diagnosed in humans using the most advanced computer-aided methods such as deep learning. The aim of this study consists of two parts. The first is to classify the tibia (fracture / no fracture) on the whole / partial digital images of cats and dogs using Mask R-CNN and SSD, one of the deep learning methods, and to localize the location of the fracture on the tibia fracture. The second is to transform the part of the backbone of the classical Mask R-CNN architecture used for feature extraction into a hybrid structure and increase the detection performance of tibia fractures in cats and dogs. In the studies, a total of 1488 dog and cat images were obtained from universities and institutions. Based on this, four different studies were conducted to detect tibia fractures. In the first phase of the first study, fracture and no fracture tibia classification was done automatically using Mask R-CNN. The fracture location of the tibia obtained from the first phase was localized in the second phase using Mask R-CNN. In the second study, Mask R-CNN was used for direct localization of the fracture location. In the third study, the fracture location on the tibia fracture obtained from the first

phase of the first study was localized using SSD. In the fourth study, the fracture areas of the dog and cat tibia fractures were determined by hybridizing the original backbone structure used on the Mask R-CNN framework. The first phase accuracy and F1 score values of the first study were 74% and 85%, respectively, and the second phase F1 score value of the first study was 84.5%. The accuracy and F1 score values of the second study were 52.1% and 68.5%, respectively. F1 score value of the third study was found to be 46.2%. The F1 score value of the fourth study was found to be 85.8%. According to the results of the study conducted in the research, it showed that the hybrid system will be beneficial in terms of protecting animal health by making more successful determinations compared to the original Mask R-CNN architecture, and that the dissemination of fracture diagnosis with the help of such intelligent systems will also be beneficial in terms of animal welfare.

**Keywords:** Cat, Deep learning, Dog, Fracture, Hybrid, Mask R-CNN, Tibia

## TEŞEKKÜR

Tez çalışmamın hazırlanma ve yürütülmesinin her aşamasında deneyimlerini ve yardımlarını esirgemeyen danışmanım Sayın Doç. Dr. Halil Murat ÜNVER başta olmak üzere, tez çalışmasının şekillenmesi ve olgunlaşmasında bilimsel desteklerini esirgemeyen Sayın Prof. Dr. Necaattin BARIŞCI'ya, Anabilim Dalı Başkanı Sayın Doç. Dr. Atilla ERGÜZEN'e, tez çalışmasının veri setini oluşturan görüntülerin temininde desteklerini esirgemeyen Ankara Üniversitesi Veteriner Fakültesi Dekanı Sayın Prof.Dr. Belgin SARIMEHMETOĞLU'na, Ankara Üniversitesi Veteriner Fakültesi Cerrahi Anabilim Dalı Başkanı Sayın Prof.Dr. Ali BUMİN'e, Kırıkkale Üniversitesi Veteriner Fakültesi Cerrahi Anabilim Dalı Başkanı Sayın Prof. Dr. Ertuğrul ELMA'ya, Selçuk Üniversitesi Veteriner Fakültesi Cerrahi Anabilim Dalı Öğretim Üyesi Sayın Prof.Dr. Celal İZCİ'ye, Ankara Büyükşehir Belediyesi Sincan Geçici Hayvan Bakım Ev Rehabilitasyon Merkezi yetkilileri ve veteriner hekimlerine, örneklerin sınıflandırılmasında uzman görüşlerini esirgemeyerek ve değerli zamanlarını ayırarak yardımcı olan Kırıkkale Üniversitesi Veteriner Fakültesi Cerrahi Anabilim Dalı Öğretim üyesi Sayın Dr. Öğr. Üyesi Ali KUMANDAŞ'a, Ankara Üniversitesi Veteriner Fakültesi Anatomi Anabilim Dalı adına orijinal kedi ve köpek tibia görüntüsü veren Prof. Dr. Çağdaş OTO'ya teşekkürü bir borç bilirim.

Bu günlere gelmemde emek sarfetmiş olan rahmetle andığım ve hayattaki büyüklerime, anneme, babama, tez sürecinde gösterdikleri destek, sevgi ve sabırdan dolayı hayattaki en değerli varlıklarım kızım Duru BAYDAN ve eşim Emine BAYDAN'a sonsuz teşekkür ederim.



# İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
<b>ÖZET</b> .....	<b>iii</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>TEŞEKKÜR</b> .....	<b>vii</b>
<b>İÇİNDEKİLER DİZİNİ</b> .....	<b>viii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>xi</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>xiii</b>
<b>KISALTMALAR DİZİNİ</b> .....	<b>xiv</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Tezin Amacı .....	2
1.2. Tezin Organizasyonu.....	3
<b>2. LİTERATÜR ÇALIŞMASI</b> .....	<b>4</b>
2.1. Kırık Tanımı .....	17
2.2. Kırığın Nedenleri.....	19
2.2.1. Dış Nedenler .....	19
2.2.2. İç (İntrinsik) Nedenler.....	20
2.3. Tibia Kemik Kırıkları.....	20
2.3.1. Köpek ve Kedilerde Tibia Kırıkları .....	21
2.3.2. Kırıkların Klinik ve Doğrulayıcı Tanı Yöntemleri .....	23
2.4. Yapay Zeka (YZ) .....	25
2.4.1. Yapay Zeka Bileşenleri .....	27
2.4.1.1. İnsan Unsuru .....	27
2.4.1.2. Bilgi Tabanı .....	27
2.4.1.3. Algoritma Seti.....	28
2.4.2. Yapay Zeka Sektörleri .....	28
2.4.2.1. Genetik Programlama .....	28
2.4.2.2. Veri Madenciliği.....	29
2.4.2.3. Örüntü Tanıma.....	29
2.4.2.4. Uzman Sistem .....	29
2.5. Makine Öğrenmesi .....	30

2.5.1.	Makine Öğrenme Algoritmaları.....	31
2.5.2.	Makine Öğrenmede Kullanılan Modeller ve Diller .....	32
2.6.	Yapay Sinir Ağları (YSA).....	32
2.7.	Derin Öğrenme .....	33
2.7.1.	Regional Proposal Network (RPN).....	36
2.7.2.	Fast R-CNN.....	38
2.8.	Evrişimsel Sinir Ağı .....	38
2.8.1.	Giriş Katmanı .....	40
2.8.2.	Evrişimsel Katman (Convolutional Layer) .....	40
2.8.3.	Havuzlama Katmanı.....	42
2.8.4.	Seyreltme Katmanı.....	42
2.8.5.	Tamamen Bağlı Katmanı .....	42
2.9.	Popüler ESA Mimarileri/Derin Öğrenme Modelleri.....	43
2.9.1.	LeNet.....	43
2.9.2.	AlexNet .....	44
2.9.3.	GoogLeNet.....	45
2.9.4.	Microsoft ResNet .....	45
2.9.5.	VGG .....	46
2.9.6.	DenseNet.....	47
<b>3.</b>	<b>MATERYAL VE YÖNTEM .....</b>	<b>50</b>
3.1.	Veri Seti.....	50
3.2.	Tibia Kırıklarının Etiketleme İşlemi .....	50
3.3.	Tibia Kemik Kırıkları Tespiti İçin Kullanılan Derin Öğrenme Yöntemleri ..	52
3.4.	Mask R-CNN.....	52
3.5.	Single Shot Detector (SSD).....	53
3.5.1.	Modelin API İçerisine Yerleştirilmesi .....	53
3.5.1.1.	Etiketleme Sonucu Oluşan Xml Dosyalarının Tensorflow'un .....	53
3.5.1.2.	Labelmap Oluşturma ve Config Dosyalarının Düzenlenmesi .....	54
3.5.2.	Geliştirilen Modelin Değerlendirme Kriterleri .....	55
<b>4.</b>	<b>BULGULAR .....</b>	<b>59</b>
4.1.	Geliştirme Ortamı.....	59
4.2.	Tibia Kırığının Tespiti İçin Önerilen Sistem Mimarisi .....	60
4.3.	Performans Değerlendirmesi .....	64

<b>5. TARTIŞMA.....</b>	<b>76</b>
<b>6. SONUÇLAR VE ÖNERİLER.....</b>	<b>79</b>
<b>KAYNAKLAR .....</b>	<b>81</b>
<b>ÖZGEÇMİŞ.....</b>	<b>95</b>



## ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
2.1 Humerus Üst Uç Kemik Kırığına Ait Örnekler .....	6
2.2 Omurga Kırıklarına Ait Görüntüler ve Kırıkların Etiketlenmesi .....	7
2.3 Convolutional Filtresinden Geçen Omurga Kırığına Ait Görüntü .....	7
2.4 ESA Ağından Geçen El Bileğinin Görüntüsü .....	8
2.5 Vücuttaki Kemiklerinin Tespiti İçin Uygulanan ESA Katmanları .....	9
2.6 Sistem Blok Diyagramı .....	10
2.7 Farklı açılardan çekilmiş köpek (A) ve kedi (B) tibiası .....	21
2.8 Derin öğrenmeye temel oluşturan bir nöron hücresi .....	33
2.9 YZ, ML ve DL arasındaki ilişki .....	33
2.10 Faster R-CNN mimaris .....	36
2.11 Konvolüsyon Aktivasyon Haritası .....	36
2.12 Anchors (Kutular) .....	37
2.13 600x800 boyutundaki bir görüntüdeki kutular .....	37
2.14 Filtrenin Uygulandığı Konvolüsyon İşlemi .....	40
2.15 CIFAR-10 Veri Seti Ağırlık Bağlantısı .....	41
2.16 Doldurma (Padding) .....	41
2.17 Maksimum Havuzlama Gösterimi .....	42
2.18 LeNet Mimarisi Gösterimi .....	43
2.19 AlexNet Mimarisinin Gösterimi .....	44
3.1 Etiketleme Aracı.....	51
3.2 Etiketlenmiş Kırık Görüntüsünün Koordinat Bilgisi .....	51
4.1 Mask R-CNN Mimarisi.....	61
4.2 SSD Mimarisi.....	61
4.3 Orijinal Mask R-CNN mimarisinin Katman Seviyesinde Görünüşü.....	62
4.4 Omurgası Hibritlendirilmiş Mask R-CNN Mimarisinin Katman Seviyesinde Görüntüsü.....	62
4.5 Önerilen Sistem Mimarisinin Akış Şeması.....	64
4.6 Bütün Vücut Görüntüsünden Tespit Edilmiş ve Sınıflandırılmış Sağlam ve Kırık Tibia Görüntüsü.....	66

4.7	Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Tibia Üzerindeki Kırık Yerinin Mask R-CNN ile Tespiti ve Belirlenmesi .....	67
4.8	Mask R-CNN Kullanarak Bütün/Kısmi Vücut Görüntüsünden Doğrudan Kırık Tibianın Kırık Yerinin Tespiti ve Belirlenmesi.....	69
4.9	Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Tibia Üzerindeki Kırık Yerinin SSD ile Tespiti ve Belirlenmesi .....	70
4.10	Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Kedi Tibia'sı Üzerindeki Kırık Yerinin Omurgası Hibridize ile Tespiti ve Belirlenmesi .....	71
4.11	Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Köpek Tibia'sı Üzerindeki Kırık Yerinin Omurgası Hibridize ile Tespiti ve Belirlenmesi .....	72

## ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
2.1	Kemik Kırığı Tespit Oranı.....11
2.2	Femur Kemik Kırığının Tespiti ve Sınıflandırılması Üzerine Performans Karşılaştırılması.....12
4.1	ResNet 101 ile Modified ResNet 101 + Dense Block (from DenseNet)'un Mimari Karşılaştırması.....63
4.2	Mask R-CNN Kullanarak Tibiadaki Kırıkların Tespit, Sınıflandırma ve Belirleme Çalışmalarının Metrik Sonuçları.....73
4.3	SSD Kullanarak Tibiadaki Kırıkların Tespit, Sınıflandırma ve Belirleme Çalışmalarının Metrik Sonuçları.....74
4.4	Omurgası Hibridize Edilmiş Mask R-CNN Kullanarak Tibia Kırığı Üzerindeki Kırık Bölgesinin Tespiti ve Belirlenmesi.....75

## KISALTMALAR DİZİNİ

<b>R-CNN</b>	Bölgesel Tabanlı Evrişimsel Sinir Ağı
<b>SSD</b>	Tek Atış Detektörü
<b>DÖ</b>	Derin Öğrenme
<b>YZ</b>	Yapay Zeka
<b>MÖ</b>	Makine Öğrenmesi
<b>BT</b>	Bilgisayarlı Tomografi
<b>MRT</b>	Manyetik Rezonans Görüntüleme
<b>ESA</b>	Evrişimsel Sinir Ağı / Convolutional Neural Network
<b>GGG</b>	Görsel Geometri Grubu / Visual Geometry Group
<b>KA</b>	Konut Ağı / ResNet
<b>ÜDA</b>	Üretici Düşmanlık Ağı / Generative Adversarial Network
<b>DOK</b>	Değişken Otomatik Algılayıcıları / Variational Auto Encoder
<b>GSEM</b>	Gri Seviye Eş Oluşum Matrisi / Gray-Level Co-Occurrence Matrix
<b>İBGYSA</b>	İleri Besleme Geri Yayılım Sinir Ağları / Feed Forward Back Propagation Neural Network
<b>DVM</b>	Destek Vektör Makinesi / Support Vector Machine
<b>NB</b>	Naive Bayes
<b>FS</b>	Füzyon Sınıflandırıcı / Fusion Classifier
<b>BŞA</b>	Boyun Şaft Açısı / Neck Shaft Angle
<b>MRA</b>	Markov Rastgele Alanlar / Markov Random Field
<b>YG</b>	Yoğunluk Gradyanı / Intensity Gradient
<b>YGZ</b>	Yapay Genel Zeka
<b>YSZ</b>	Yapay Süper Zeka
<b>YSA</b>	Yapay Sinir Ağları / Artificial Neural Network
<b>DDİ</b>	Doğal Dil İşlemesi
<b>KEK</b>	K En Yakın Komşu
<b>EKVR</b>	En Küçük Kareler Vektör Regresyonu
<b>SRA</b>	Sınıflandırma ve Regresyon Ağacı
<b>GRSA</b>	Genel Regresyon Sinir Ağları
<b>GYS</b>	Gerilim Sinir Ağları
<b>DSA</b>	Derin Sinir Ağı

<b>TSA</b>	Tekrarlayan Sinir Ađı
<b>UKSBA</b>	Uzun Kısa Süreli Bellek Ađları
<b>YOK</b>	Yıđınlanmış Otomatik Kodlayıcılar
<b>DBM</b>	Derin Boltzman Makinesi
<b>DİA</b>	Derin İnanç Ađları
<b>BTA</b>	Bölgesel Teklif Ađı / Regional Proposal Network
<b>BÜK</b>	Birlik Üzerinden Kesişim / Intersection Over Unit
<b>UPA</b>	Uygulama Program Arabirimi / Application Program Unit
<b>GİB</b>	Grafik İşleme Birimi / Grapical Processing Unit
<b>KYM</b>	Kırmızı Yeşil Mavi / Red Green Blue
<b>MOB</b>	Maksimum Olmayan Bastırma / Non Max Supression
<b>İB</b>	İlgi Bölgesi / Region Of Interest
<b>EÖM</b>	Ekstra Öğrenme Makinesi
<b>DDB</b>	Doğrultulmuş Doğrusal Birim / Rectified Linear Unit
<b>İAT</b>	İnsan Aktivite Tanımlama
<b>KTB</b>	Kapalı Tekrarlayan Birim
<b>TP</b>	Doğru Pozitif
<b>FP</b>	Yanlış Pozitif
<b>FN</b>	Yanlış Negatif
<b>TN</b>	Doğru Negatif



## 1. GİRİŞ

Mağaralardaki çizimlerden insanların tarih öncesi yıllardan itibaren hayvanlarla iç içe olduğu anlaşılmaktadır. İnsan-hayvan bağı, insanlar ve hayvanlar arasında her iki tarafın da sağlığı ve refahı için gerekli olan karşılıklı fayda sağlayan bir ilişki olarak tanımlanmaktadır. Evcil hayvanlar çocuklarda eğitsel ve bilişsel yararlar sağlarken, yetişkinlerde kalp-damar hastalıklarında azalma ve yalnızlık duygusunun en aza indirilmesi şeklinde fiziksel ve psikolojik yararları sağlamaktadır. Bu yararlardan dolayı insanın ayrılmaz bir parçası olan ve bazı hastalıkların tedavisinde “pet terapisi” adıyla yapılan uygulamalarda yararlanmak üzere istihdam edilen kedi, köpek gibi refakatçi (arkadaş) hayvanların sahiplenilmesi ülkeler bazında giderek artmıştır [1,2]. Bu kapsamda Kuzey Amerika’lıların yaklaşık %70’inin hayatında en az bir pet hayvanının olduğu bildirilmektedir [1].

Hayvanlar acı ve sıkıntı hissetme duygularının yanısıra, türlere göre değişkenlik gösterebilen, çevreye ve koşullara uygun rahatlık, zevk veya ilgi gibi olumlu deneyimler yaşama yeteneğine sahip canlılardır [1]. Hayvan refahı konusu, 1960’lı yıllardan önce ilk defa hayvan hakları şeklinde Avrupa’da bazı yasal düzenlemelerle gündeme gelmiştir. Ancak, son yıllarda konu üzerine odaklanmalar daha da artmıştır; bunda, basılı ve görsel yayınlarla toplum bilincindeki artış, konu ile ilgili sivil toplum örgütlerinin sayıca artması, çıkarılan yasal düzenlemeler ve bu düzenlemelerin giderek daha da iyileştirilmesi gibi faktörler etkili olmuştur [3]. Çoğu evcil hayvanın AB ülkelerinde iyi muamele gördüğü kabul edilmekle birlikte, bazı üye ülkelerde özellikle başıboş köpeklerle ilgili önemli sorunların olduğu vurgulanmaktadır [4].

Hayvan refahı, “zenginlik ve mutluluk” anlamına gelen İngilizce kökenli “welfare” sözcüğüyle Avrupa yasalarına girmiştir [3]. Hayvan refahı farklı şekillerde tanımlanmakla birlikte kısaca "hayvanların fiziksel ve psikolojik, sosyal ve çevresel refahı" olarak bildirilmektedir [1]. Avrupa Birliği (AB)’nin 98/58 / EC kodlu önsözünün 7. paragrafında "*deneyimlerle belirlenmiş ve bilimsel bilgiye uygun olarak hayvanların fizyolojik ve etyolojik ihtiyaçlarına uygun barınma, yiyecek, su ve bakım sağlanması*" ifadesi olarak geçmektedir [4]. Ancak, refah kelimesi hayvanlarla ilgili olarak oldukça geniş bir kapsama alanına sahiptir. Hayvanlarda refahı etkileyen

başlıca faktörler “hastalıklar, yaralanmalar, uyarılar, sosyal ilişkiler, barınma şartları, hastalıklarda kullanılan özel tedaviler, insan tarafından yapılan sevk ve idare işlemleri, nakil, laboratuvar uygulamaları, çeşitli sakatlanmalar, veteriner hekim müdahaleleri ve klasik yollarla veya gen mühendisliğini kullanarak hayvan genotipinin değiştirilmesi” olarak sıralanabilmektedir. Fakat, hayvan refahının pek çok alanla da ilişkileri olduğu bilinmektedir. Bu kapsamda hayvan sağlığındaki bozulma refahı etkileyen önemli faktörlerden biridir [3].

Sağlık ve refah terimleri, insan ve hayvanlar için tamamen aynı anlama sahiptir [4]. Sağlıkla ilgili veteriner hekimlik alanındaki uygulamalar hayvan refahının önemli bir parçasını oluşturur [1]. Hastalıklı hayvanlar çoğu kez çevreleriyle baş etmekte güçlük çekerler veya bunu başaramazlar, bu nedenle başka türlü benzer koşullarda refahları sağlıklı bir hayvanınkinden daha zayıftır. Hastalığın ağrıya veya başka türden rahatsızlıklara ya da sıkıntıya neden olmasına bakılmaksızın hastalığın etkilerini azaltan veteriner tedavisi hayvan refahını iyileştirmeye yönelik bir uygulamadır [4]. Mesleki ve toplumsal beklentiler, veteriner hekimlerin hayvan refahını geliştirmede öncü olmaları ve hayvan hastalarına ilişkin bilinçli tıbbi ve etik seçimler yapmaları yönündedir [5].

Hayvanlara mümkün olan en iyi yaşam kalitesini, fiziksel sağlık sağlamayı, acılarını/ızdıraplarını giderme veya en aza indirmeyi ve doğal davranışlarını sergilemelerini sağlamak insanların hayvanlara olan borcudur. Hayvanların insanlarla oynadığı her rol için bir refah değerlendirmesi ve sorunları azaltma planı yapılması gereklidir. Bunlar gerçekleştiği zaman toplumda insan yararına pek çok görevler üstlenen köpek ve kedilerle ilgili sosyal sözleşme ve görevler yerine getirilmiş olacaktır [6].

### **1.1. Tezin Amacı**

Bu çalışmanın amacı derin öğrenme yöntemleri kullanarak veteriner klinisyenler için tibiadaki kırığın daha doğru, hızlı ve güvenli bir şekilde teşhis edilmesi adına kedilerin ve köpeklerin bütün/kısmi dijital görüntüleri üzerinde tibiayı kırık/kırık değil olarak sınıflandırmak ve kırık olarak tespit edilmiş tibialar üzerinde kırığın yerini belirlemektir.

Son olarak köpek ve kedi tibia kırıklarındaki kırık bölgelerinin tespitini daha hızlı ve daha yüksek performans sağlayabilmek için Mask R-CNN mimarisinde kullanılan orjinal omurga yapısı hibrit hale getirilmiştir. Böylece akıllı sistemler yardımıyla kırık teşhisinin yaygınlaştırılmasının hayvan refahı yönünden yararı gösterilmiş olacaktır.

## **1.2. Tezin Organizasyonu**

Tezin ikinci bölümünde Yapay Zeka ile sağlık alanında dijital röntgen üzerinden yapılan otomatik tespit çalışmaları ve derin öğrenme ile bilgisayar destekli sistemler kullanılarak kemik kırıklarının otomatik tespitine ilişkin literatür çalışmalarına değinilmiştir.

Üçüncü bölümde, tibiaya ilişkin veteriner hekimliğine ait bilgilere değinilmiş, tibia kırıklarının sınıflandırılması ve tespitinde kullanılan metotlar açıklanmıştır.

Dördüncü bölümde tibiaya ilişkin hem sağlam hem de kırık kemiklerinde kullanılan veri setleri anlatılmış, geliştirme ortamından bahsedilmiş, tibia kırığının tespiti için önerilen sistem mimari açıklanmış ve elde edilen sonuçlar literatürdeki benzer çalışmalarla önerilen sistem karşılaştırılarak tartışılmıştır.

Tezin son bölümünde ise elde edilen sonuçlardan bahsedilmiş ve ileride yapılabilecek çalışmalar için öneriler sunulmuştur.

## 2. LİTERATÜR ÇALIŞMASI

Derin Öğrenme (DÖ), görüntü tanıma, konuşma tanıma ve doğal dil işlemede yaygın olarak benimsenmiştir, ancak sağlık hizmetlerini daha yeni yeni etkilemeye başlamıştır [7]. Tıpta yapay zeka (YZ) araştırmaları giderek artan bir şekilde makine öğrenimi (MÖ) tekniklerini karmaşık sorunlara uygulamaya ve böylece bilgisayarların kendi ilişkilerini öğrenerek büyük miktarda hasta verisinden tahminler yapmasına izin vermeye odaklanmaktadır. Makine öğrenimi araştırmasındaki eğilimler “Klinik karar destek sistemleri” tıpta yaygın bir şekilde kullanılmaktadır ve ilaçların güvenli reçetelenmesi, kılavuza uyma, basit risk taraması veya prognostik puanlama konusunda rehberlik sağlama alanlarında en fazla etkiye sahiptir [8]. Tıpta derin öğrenme, diyabetik retinopati ve prematüre retinopatisi, glokom benzeri disk, makula ödemi ve yaşa bağlı maküler dejenerasyonun saptanması gibi oftalmoloji alanında [7], malign melanom ve tüberküloz tanısında insanlarla karşılaştırılabilir ölçüde yetenekler göstermiştir [9]. Tıbbi görüntüler için röntgen, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG) ve ultrason gibi veri türleri klinik uygulamalar için yüksek potansiyele sahip önem oluşturmaktadır. Bu veriler insan hatalarını en aza indirerek hastalıkların otomatik olarak tespit edilmesine, çalışma protokolleri oluşturulmasına, görüntü kalitesini iyileştirerek radyasyon dozunu azaltmaya, MRG tarayıcı süresini azaltmaya, personel ve tarayıcı kullanımını optimize etmeye ve böylece maliyetleri düşürmeye yardımcı olur [10]. Teşhis desteği dışında tıpta MÖ sistemleri, diğer karar desteği türleri için, örneğin çok sayıda karmaşık faktöre dayalı risk tahminleri yapmak (Örn. sepsis için) veya belirli tedavi türlerini bireylere göre uyarlamak, kanserli bir hastanın BT taramalarını analiz ederek bu verileri önceki hastalardan öğrenilenlerle birleştirmek, yakındaki organlara verilen zararı en aza indirmek için hastaya özel bir radyasyon tedavisi önerisi sunan sistemler geliştirmek gibi alanlarda kullanılmak üzere artık klinik uygulamaya girmektedir [8]. Kısaca YZ uygulamaları, doktorlar da dahil olmak üzere birçok profesyonelin çalışma metodolojilerini değiştirecek ve bu da özellikle radyolojide diğer tıp alanlarına göre daha hızlı gerçekleşecek gözükmemektedir [10]. İngiltere’de özellikle tıpta son yıllarda radyoloji hizmetlerine olan taleplerdeki ciddi artışlar ve iş gücü yetersizliğine bağlı olarak raporlamalardaki sorunlara bağlı olarak gecikmiş ya da kaçırılmış tanıdan

dolayı hastaya zarar verebilme olasılığını minimize etmede raporlama sistemlerinin iyileştirilmesi gereklilikleri vurgulanmaktadır [11].

YZ sistemleri geliştirmek için makine öğrenmesi kritik bir unsurdur. Konuyla ilgili bulgu ve tanımlarla birlikte veri seti görüntülerinin bir radyolog tarafından yorumlanması, doğru ve kaliteli olanların kabul edilip yetersiz olanların reddedilmesi noktasında, kısaca tanılabilir performansı artırmada radyologlar altın standart değerindedir [9].

Tıpta ve radyolojide YZ'nin zorlukları algoritma geliştirmedeki ilerleme, hesaplama kaynaklarına erişim kolaylığı ile birleştiğinde tıbbi karar verme görevlerinde umut verici sonuçlara ulaşılmasına fırsat vermektedir. Derin öğrenme algoritmaları şu anda meme kanseri tespiti için mamografide, kolon kanseri teşhisi için BT'de, akciğer nodüllerinin tespiti için göğüs radyografilerinde, beyin tümörü segmentasyonu için MRG'de ve Alzheimer hastalığı gibi nörolojik bozuklukların teşhisi için kullanılmaktadır. Ancak, tıpta ve özellikle radyolojide, hekimlere değil, düzenleyici kurumlara ve hükümetlere bağlı olan YZ uygulamalarının zorlukları vardır [10].

Tıbbi görüntüleme analizi için yapay zeka sistemi oluşturmanın on adımı Ting ve ark (2019) tarafından şu şekilde bildirilmiştir;

1. Klinik bir ihtiyacı veya araştırma sorusunun belirlenmesi
2. Veri kümelerinin seçimi - eğitim, doğrulama ve testin bölünmesi
3. ESA'ların Seçimi (ör. AlexNet, VGGNet, ResNet, DenseNet, Ensemble)
4. DÖ sistemlerini oluşturmak için yazılım seçimi - Keras, Tensorflow, Cafe, Python
5. ImageNet'te transfer öğrenme / ön eğitimin kullanımı
6. Ayarlama ve optimizasyon için geri yayının kullanımı
7. Veri kümelerinin özelliklerinin raporlanması - hastaların demografik özellikleri, retina görüntüsü ve hastalık özellikleri
8. Yerel ve harici doğrulama veri setlerinde teşhis performansının raporlanması - eğri altındaki alan, duyarlılık ve özgüllük, doğruluk ve kappa
9. Teşhisi açıklamak için ısı haritasının kullanımı - farklı ısı haritası türleri (oklüzyon testi, yumuşak dikkat haritası, entegre gradyan yöntemi)

## 10. Retina görüntüleme yeni yöntemler - GAN, VAE ve potansiyel klinik uygulamaları

Bugüne kadar bilgisayar desteği ile kemik kırıklarının tespiti ve sınıflandırma işlemlerine yönelik çalışmalar farklı teknikler kullanılarak gerçekleştirilmiştir. Genel olarak kemik kırıklarının tespiti ve sınıflandırılması için Derin Öğrenme ve Görüntü İşleme teknikleri kullanılmıştır.

Bu kapsamda yapılan bir çalışmada DÖ teknolojisi kullanılarak insan humerus (kol kemiği) üst uç kırıklarının tespiti ve sınıflandırılması gerçekleştirilmiştir. Bu çalışmada 1891 omuz röntgen görüntüleri kullanılmıştır. Görüntüler Konkuk Üniversitesi Medical Center, Kyungpook Ulusal Üniversite Hastanesi, Myungji Hastanesi, Kangwon Ulusal Üniversite Hastanesi, Ulusal Polis Hastanesi, Seoul Saint Mary Hastanesi ve Wonkwang Üniversite Sanbon Hastanesinden temin edilmiştir. Dört farklı tipte humerus üst uç kırığı (greater tuberosity, surgical neck, 3 parçalı ve 4 parçalı) 3 uzman tarafından etiketlenerek sınıflara ayrılmıştır. Dört farklı tipte humerus üst uç kırığına ait görüntüler Şekil 2.1’de verilmiştir. Şekil 2.1’de görüldüğü üzere A grubu normal humerus kemiğine ait görüntüyü, B grubu greater tuberosity kırığına ait görüntüyü, C grubu surgical neck kırığına ait görüntüyü, D grubu 3 parçalı kırığa ait görüntüyü, E grubu 4 parçalı kırığa ait görüntüyü içermektedir. DÖ teknolojisine ait ESA (Evrşimsel Sinir Ağı) metodu kullanılarak bir kırık tipinin diğer kırık tiplerinden ayırabilme performansı greater tuberosity kırığı için %86, surgical neck kırığı için %80, 3 parçalı kırık için %65, 4 parçalı kırık için %75 olarak sonuç vermiştir [12].




Şekil 2.1 Humerus Üst Uç Kemik Kırığına Ait Örnekler [12]


Başka bir çalışmada DÖ ait ESA metodu kullanılarak omurgadaki kırıkların tespiti yapılmıştır. Bu çalışma 18 kadın/erkek hastanın omurga kırığına ait röntgen

görüntülerinin 55 bölgede uzman kişi tarafından etiketlenerek yapılmıştır. Görüntüler Kaliforniya Üniversitesi Irvine Medical Center'dan temin edilmiştir. Etiketleme işlemine ait görüntüler Şekil 2.2'de verilmiştir. Şekil 2.2'de kırmızı renge ait bölümler kırığın etiklendiği bölgeyi göstermektedir.

Bu çalışmada ESA metodunu uygularken 5 konvolüsyonel katman, 3 tamamen bağlı katman ve sınıflandırma için softmax katmanı kullanılmıştır. Şekil 2.3'te konvolüsyonel katmandan çıkan omurga kırığına ait görüntü verilmiştir. Omurgaya ait kırığın olup olmadığına göre sınıflandırma performansı %71 veya %81 hassasiyette sonuç vermiştir [13].

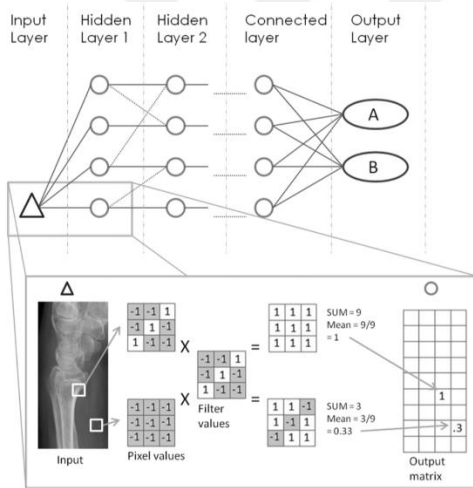


Şekil 2.2 Omurga Kırıklarına Ait Görüntüler ve Kırıkların Etiketlenmesi [13]



Şekil 2.3 Convolutional Filtresinden Geçen Omurga Kırığına Ait Görüntü [13]

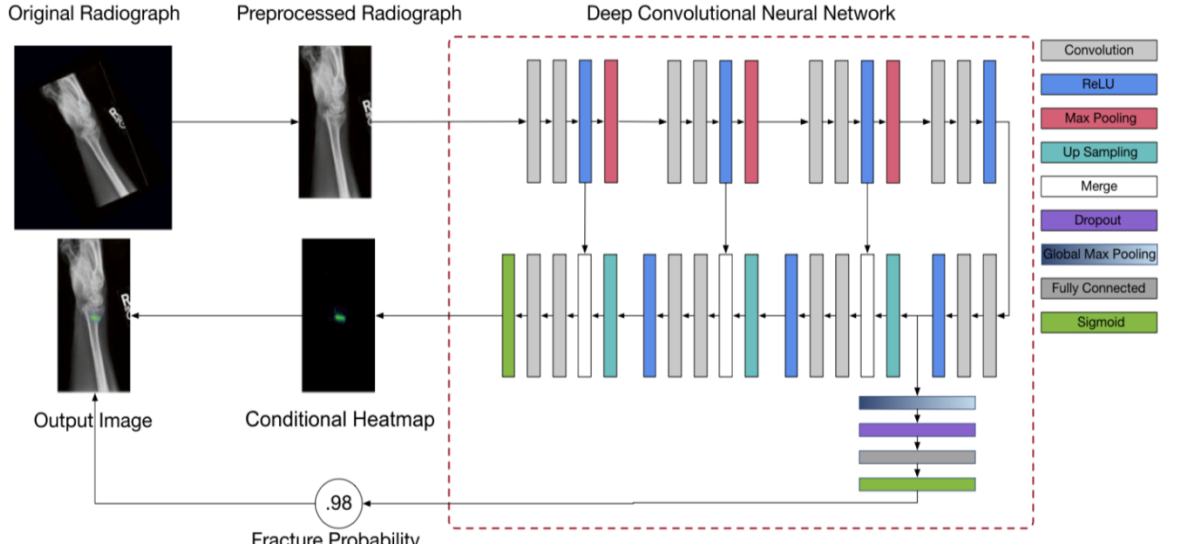
Bir diğerk çalışmada el bileđi kırığının tespiti için Derin Öğrenme teknolojisi kullanılmıştır. Ocak 2015 ile Ocak 2016 yılları arasına ait el bileđi röntgen görüntüleri Royal Eveon ve Exeter Hastanesinden elde edilmiştir. Bu görüntülerin 695 adeti kırık el bileđi ve 694 adeti kırık olmayan el bileđi görüntülerini içermektedir. Bu görüntüleri ESA'ya vermeden önce görüntüler ön işlemeden geçirilerek “Red Spot” anotasyonlarından giderilir ve böylece ezberlemeden (over-fitting ) kurtulmuş olunur. Ayrıca, eğitim verilerinin çoğaltılması için data augmentation tekniđi kullanılmıştır. Görüntü ön işleme aşamaları bittikten sonra görüntüler ESA'ya verilir ve ESA'daki temel filtrelerden geçirilir. Bu filtreler geri yayılım (BackPropogation ) tekniđi kullanılarak eğitim işlemleri tarafından geliştirilir. Geri yayılım tekniđi sayesinde ağdaki hata minimize edilmiştir. ESA ağından geçen el bileđinin durumunu gösteren görüntü Şekil 2.4'te verilmiştir. Kırığın doğru şekilde tespit edilme hassasiyeti %95 olarak görülmüştür [11].



Şekil 2.4 ESA Ağından Geçen El Bileđinin Görüntüsü [11]

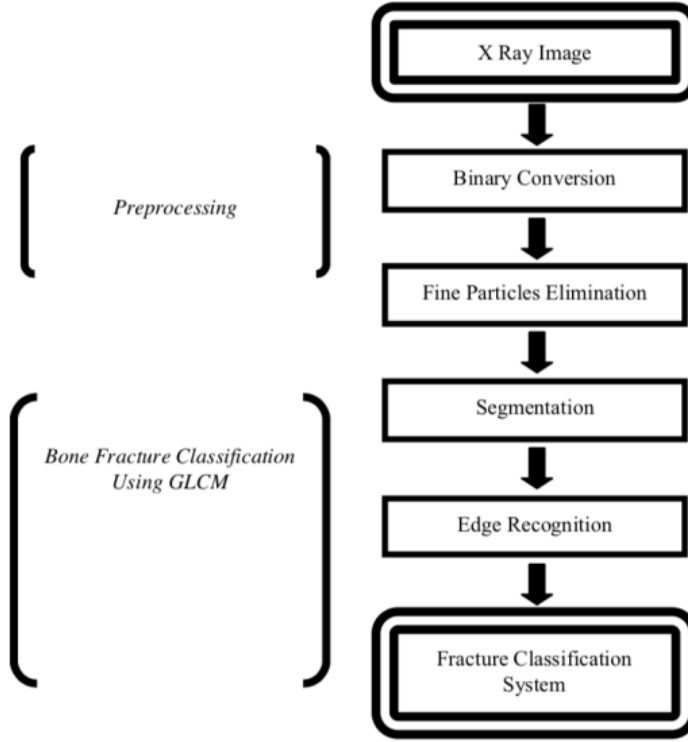
Lindsey ve arkadaşları (2018) tarafından yapılan bir çalışmada Derin Öğrenme teknolojisinin kemik kırığı tespitinin klinisyenler tarafından geliştirilmesi amaçlanmıştır. Röntgen görüntüleri Özel Cerrahi Hastanesinden Eylül 2000 ile Mart 2016 tarihleri arasında toplanmıştır. 135545 adet röntgen görüntüsü insan vücudunun farklı bölümlerini içermektedir. Kırıkların tespiti için ESA metodu kullanılmıştır. ESA metodu için uygulanan katmanlar Şekil 2.5'te gösterilmiştir. Tespit etme performansı %82,7 hassasiyette sonuç vermiştir [14].





Şekil 2.5 Vücuttaki Kemiklerinin Tespiti İçin Uygulanan ESA Katmanları [14]

Bugüne kadar kemik kırıklarının tespiti ve sınıflandırması için kullanılan Derin Öğrenme teknolojisi yanında diğer bir teknoloji olan “Görüntü İşleme” yöntemleri de kullanılmıştır. Chai ve arkadaşları (2011)’nın yaptığı çalışmada Görüntü İşleme tekniği olan Gri Seviye Eş Oluşum Matrisi (GSEM) kemik kırıklarının tespitinde kullanılmıştır. Görüntü olarak Femur kemiğine ait röntgen görüntüleri kullanılmıştır. Görüntü üzerindeki gürültüleri ortadan kaldırmak için görüntü ön işleme teknikleri uygulanmıştır. Bunlar İkili Dönüştürme (Binary Conversion) ve İnce Parçacıklarının Eliminasyonu (Fine Particles Elimination) teknikleridir. Daha sonra kırık kemiğin sınıflandırılması için GSEM kullanılmıştır. Şekil 2.6’de sistemin blok diyagramı verilmiştir. Sonuç olarak geliştirilen yöntemin kırık sınıflandırmasındaki doğruluğu %86.67 olmuştur [15].



Şekil 2.6 Sistem Blok Diyagramı [15]

Görüntü İşleme tekniği kullanılan bir başka çalışmada Tibia kemik kırığının tespiti çalışma konusu olarak ele alınmıştır. Bu çalışmada kemik kırığının tespiti için görüntü işleme adımlarından önileme, segmentasyon ve özellik çıkarımı kullanılmıştır. Sınıflandırma içinse İleri Besleme Geri Yayılım Sinir Ağı (İBGYSA), Destek Vektör Makinesi (DVM) ve Naive Bayes (NB) sınıflandırıcı ve füzyon sınıflandırıcı (FS) teknikleri ile kullanılmıştır. Bu çalışma için 1000 adet test röntgen görüntüsü ve 400 adet kırık kemik ve 250 adet sağlam kemik olmak üzere 650 adet eğitim röntgen görüntüsü kullanılmıştır. Kullanılan sınıflandırma algoritmalarını kırık ve kırık olmayan kemiğin tespitinin doğruluk oran Çizelge 2.1’de verilmiştir [16].

Çizelge 2.1 Kemik Kırığı Tespit Oranı [16]

<b>Kemik Tipi</b>	<b>İBGYSA</b>	<b>DVM</b>	<b>NB</b>	<b>FS</b>
Kırık Kemik	83.12	85.71	86.08	91.27
Kırık Olmayan Kemik	92.96	94.55	95.91	98.43

Lim ve arkadaşları (2004) tarafından gerçekleştirilen bir başka Görüntü İşleme çalışmasında Femur ve Radius kırıklarının tespiti incelenmiştir. Kemik kırığının tespiti için 4 farklı tipte görüntüden özellik çıkarımı tekniği kullanılmıştır. Bunlar sırasıyla femoral boyun shaft açısı (BŞA), Gabor filtresi, Markov Rastgele Alanları (MRA) ve yoğunluk gradyan (YG)'dir. Sınıflandırma içinse Bayesian ve Support Vector Machine sınıflandırıcıları kullanılmıştır. Çizelge 2.2'de kemik kırığının tespit oranı ve sınıflandırma doğruluğuna ait sonuçlar verilmiştir [17].

Hayvanlarda kemik anatomisi üzerine yapılan çalışmalar çok azdır. Derin öğrenme teknolojisinin kullanıldığı domuz kemikleri üzerine bir çalışma olmasına rağmen, bu çalışma kırık tespiti değil, sınıflandırma üzerinedir [18]. Hayvanlarda derin öğrenme teknolojilerinden SSD kullanılarak kemik kırıklarının ilk retrospektif çalışması köpek tibiası üzerine gerçekleştirilmiştir [19]. Daha sonra bu çalışmalara takiben Baydan ve Ünver tarafından Mask R-CNN çatısı kullanılarak köpek ve kedilerdeki sağlam ve kırık tibia kemiğinin sınıflandırılıp kırık tibia üzerindeki kırık yerlerinin belirleme işleminin gerçekleştirildiği görülmüştür [20].

Yapılan çalışmalara göre kemik kırığının tespiti ve sınıflandırılmasına yönelik genel olarak Derin Öğrenme ve Görüntü İşleme teknikleri ağırlıklı olarak kullanılmıştır. Bu çalışmaları göz önünde bulundurarak daha hızlı ve daha hassas doğrulukta sonuç elde edebilmek için Derin Öğrenme teknolojisine ait olan ve nesne tespiti ve sınıflandırılmasında en yaygın olarak tercih edilen ESA'ya ait modellerin köpek Tibia kemik kırığının tespiti ve sınıflandırılması adına kullanılması hedeflenmiştir.

Çizelge 2.2 Femur Kemik Kırığının Tespiti ve Sınıflandırılması Üzerine Performans Karşılaştırılması [17]

	NSA	Gabor		YG		MRA	Birleşimi			
		Bayes	DVM	Bayes	DVM	DVM	1 of 5	1 of 6	2 of 6	2 of 4
Kırık Tespit Oranı	61.5%	53.9%	69.2%	38.5	53.9%	14.3%	100%	100%	92.2%	76.9%
Sınıflandırma Doğruluğu	93.5%	94.4%	93.5%	88%	93.5%	89.5%	89.8%	88.9%	98.2%	97.2%

Bir ya da birden fazla Evrişimsel Sinir Ağına ait metotların birleşmesi sonucu oluşan modeller hibrit bir mimari oluşturmuştur. Tek başına kullanılan metotların doğruluk oranlarını artırabilmek için hibrit ESA modeller kullanılmıştır.

Chen ve arkadaşlarının (2019) yaptıkları bir çalışmada nesnelerin örneklemelemlerini bölütleyebilmek için hibrid görev basaklama geliştirmişlerdir. Basamaklama, çeşitli görevlerde performansı artıran klasik ama güçlü bir mimari olmuştur. Ancak, örnek segmentasyonuna basamaklamanın nasıl ekleneceği açık bir sorudur. Cascade R-CNN ve Mask R-CNN'nin basit bir kombinasyonu yalnızca sınırlı kazanç sağlamıştır. Daha etkili bir yaklaşımı keşfederken, başarılı bir örnek segmentasyon kademesinin anahtarının, algılama ve segmentasyon arasındaki karşılıklı ilişkiden tam olarak yararlanmak olduğu görülmüştür. Bunun üzerine yeni Hibrit Görev Basamaklama çatısı önerilmiştir [21].

Bir başka çalışmada röntgen görüntüsünden karaciğer ve tümör'ün bölütlenmesi için Hibrit Yoğun Bağlı UNet kullanılmıştır ve adına H-DenseUNet adı verilmiştir. H-DenseUNet, dilim içi özellikleri verimli bir şekilde çıkarmak için bir 2D ve hiyerarşik olarak karaciğer ve tümör segmentasyonunu otomatik bağlam algoritmasının altında hacimsel bağlamaları toplama için bir 3D karşılıktan oluşturulmuştur. Derin evrişimli 2D DenseUNet, yüksek seviyeli temsili düzlem içi özellikler üretebilmiştir, ancak 3D DenseUNet'in büyük GİB'i varken z boyutu boyunca uzamsal bilgileri ihmal etmiştir. Daha iyi karaciğer tümörü segmentasyonu için öğrenilen dilim içi ve dilim içi özellikleri birlikte birleştirmek ve optimize etmek için H-DenseUNet geliştirilmiştir [22].

Kannoja ve Jaiswal'in yaptıkları çalışmada ESA'nın özellik temsilinden ve EÖM'nin hızlı sınıflandırma öğrenmesinden yararlanmak için, görüntü sınıflandırması için Hibrit ESA-EÖM modeli geliştirmişlerdir. Görüntü temsil özellikleri, Evrişimli Sinir Ağı tarafından öğrenilmiştir ve sınıflandırma için Ekstrem Öğrenme Makinesi'ne beslenmiştir. Üç hibrit ESA-EÖM paralel olarak bir araya getirilmiştir ve nihai çıktı, bu sınıflandırıcının çıktılarının çoğunluk oylama grubu tarafından hesaplanmıştır. MNIST veri seti üzerinde denen bu toplu modelin sınıflandırıcının sınıflandırma güvenini ve doğruluğunu iyileştirdiğini göstermiştir. 99,33'e varan doğrulukla tek

hibrit ESA-EÖM sınıflandırıcısına kıyasla doğruluğu etkili bir şekilde iyileştirdiği göstermiştir [23].

ESA'lar birkaç farklı katmandan oluşmuş (Evrışimli katmanlar, Alt örnekleme katmanları ve Etkinleştirme katmanları gibi) ve her katman, giriş verilerinde önceden belirlenmiş bazı işlevleri gerçekleştirmiştir [24]. Evrışimli katmanlar, ağdaki erken evrışimli katmanlar düşük seviyeli özellikleri (kenarlar gibi) çıkarırken ve daha karmaşık anlamsal özellikleri (araba farları gibi) çıkaran sonraki katmanlar ile görüntü sınıflandırması için kullanılacak özellikleri çıkarmıştır. Geri yayılım işlemi [25] ile, bir ESA, bir dizi girdi görüntülerinden çekirdek ağırlıkları ve önyargıları öğrenmiştir. Bu çekirdek ağırlıkları, öge bazında bir nokta ürünü gerçekleştiren bir girdi görüntüsü boyunca kayarak, daha sonra öğrenilen önyargı değeriyle birlikte toplanan ara sonuçlar vermiştir. Her nöron giriş görüntüsüne göre bir çıktı almıştır. Bu çıktılara aktivasyon haritaları [26] olarak da ifade edilmiştir. Ezberlemeyi engellemek için ESA'lar, havuzlama [27] adı verilen başka bir katman türü kullanarak girişleri altörneklemiştir. Doğrultulmuş Doğrusal Birim (ReLU) [28], argümanın pozitif bölümünü veren  $\max(0, x)$  olarak tanımlanmıştır. Bu işlevler genellikle sınıflandırma puanlarını normalleştirmek için çıktı katmanından önce kullanılmıştır. Softmax [29] ile toplamı bir olan çıktı sınıfı puanları vermek için logit olarak bilinen ölçeklenmemiş ölçek değerleri üzerinde bir normalleştirme gerçekleştirmiştir. Aşırı parametreleştirilebilen ve görüntü verilerindeki doğal özelliklerden yararlanamayan klasik görüntü sınıflandırma modelleriyle karşılaştırıldığında, ESA'lar birden çok yığılmış hesaplama katmanları aracılığıyla uzamsal farkındalığa açığa çıkartmıştır [24]. ESA'ların temel faydası, eğitilmelerinin daha kolay olması ve aynı sayıda gizli birimle tam bağlı ağlara göre çok daha az parametreye sahip olmalarıdır [23].

Ekstrem öğrenme makinesi, tek gizli katmanlı ileri beslemeli sinir ağını eğitmek için geliştirilmiştir. EÖM'de, gizli katmanın gizli düğümleri rastgele başlatılmıştı ve ardından yinelemeli ayar yapılmadan sabitlenmiştir. Nihai karar verme olarak çoğunluk oylama topluluğu bu model için kullanılmıştır. Çoğunluk oylama şeması, önce her bir temel sınıflandırıcı tarafından alınan toplam oyu hesaplar. Tahmin edilen sınıf etiketi için oy çoğunluğu hesaplanır. Nihai tahmin, çoğunluk oyu alan temel sınıflandırıcı tahminine atanır [23].

Derin Öğrenme üzerine diğer bir hibrit çalışması ise İnsan Aktivite Tanımla (İAT) olmuştur. İAT, yaşlıların günlük yaşamını desteklemek ve bilişsel bozukluklar, Parkinson hastalığı, demans vb. muzdarip kişilere yardımcı olmak için en yararlı teknoloji araçlarından biridir. Bu çalışmada, ESA'ları dört güçlü TSA (Tekrarlayan Sinir Ağları) ile, yani UKSB'ler (Uzun Kısa Süreli Bellekler), İkiUKSB'ler (İki Yönlü Uzun Kısa Süreli Bellekler), KTB'ler (Kapılı Tekrarlayan Birimler) ve İkiKTB'ler (İki Yönlü Kapılı Tekrarlayan Birimler) ile entegre eden dört hibrit modeli analiz edilmiştir. İAT teknikleri, ortam ve akıllı telefon sensörleri tarafından toplanan verilere dayanmaktadır. Bu çalışmada PAMAP2 verileri kullanılmıştır. Bu veri seti, giyilebilir sensörler tarafından toplanan 18 günlük aktivitenin verilerini içerir. Yürüme, koşma, bisiklete binme ve araba kullanma, bu veri setinde yer alan etkinliklere bazı örneklerdir. Yapılan çalışmalara göre demanstan muzdarip yaşlıların günlük aktivitelerini tanımak ve anormal davranışlarını tespit etmek için ESA ile TSA'nın birleşimi olan ve UKSB olarak adlandırılan model İAT'da daha iyi sonuç vermiştir. ESA ve TSA modellerinin kombinasyonu yoluyla, hem ESA'ların gücünü öznelik çıkarmada hem de TSA'ların aktiviteler arasındaki geçici bağımlılıkları göz önünde bulundurma kapasitesini kullanabilmiştir. TSA'lar, dahili bir bellek içeren bir YSA türüdür. UKSB'ler, bağımlılıkları uzun süre hatırlamak söz konusu olduğunda standart TSA'lardan çok daha iyi performans gösteren TSA'ların bir uzantısıdır. Çift yönlü UKSB'ler, bir kez veri dizisinin kendisi ve bir kez de ters kopyası üzerinde eğitilen UKSB'lerin bir uzantısıdır. KTB'ler, UKSB'lere benzer şekilde TSA'larda kısa süreli bellek sorununu ele alan TSA'ların başka bir uzantısıdır. İki KTB'ler, biri normal zaman düzeninde diğeri ters zaman düzeninde çalışan iki KTB'nin birleşimidir [30].

Diğer bir bilgisayar destekli tanının Pulmoner nodülün malignite riski farklılaşması ilişkin yapılan çalışmada hibrit bir model geliştirilmiştir. Lung Image Database Consortium ve Image Database Resource Initiative (LIDC-IDRI) tarafından oluşturulan en büyük genel veritabanını kullanarak pulmoner nodül farklılaşması için hem global hem de yerel özellikleri dikkate alan bir hibrit model oluşturulmuştur [31]. Son yıllarda akciğer kanseri taraması için yaygın olarak kullanılan bilgisayarlı tomografi (BT) ile her yıl çok sayıda ve artan sayıda pulmoner nodül tespit edilmesine rağmen, uzmanlar veya radyologlar tarafından tespit edilen çok sayıda nodülü

değerlendirme görevi hala çok zaman alıcı olmuştur [32]. Bu sebeple geliştirilen hibrit ESA modelinde çıkarılan özelliklerin dağılımlarının projeksiyonuna dayanarak çok kanallı ESA modelinin nodüllerin malignite riskini ayırt etme becerisinin sağlandığı gözlemlenmiştir. Bu çalışmada hibrit model geleneksel doku yöntemi ve ESA ile ilgili tamamlayıcı özellikleri hesaba katarak, geleneksel özellikleri ESA'ya dahil ederek oluşturulmuştur [31].

Sirinivas ve Sasibhushana tarafından yapılan çalışmada beyin MR görüntüleri üzerinden tümörün sınıflandırmasına ilişkin hibrit ESA-KEK (K En yakın Komşusu) modeli geliştirilmiştir. ESA modelinin özellikleri çıkardığı ve daha sonra sınıfları tahmin etmek için KEK sınıflandırıcısına uygulanmıştır. Bu çalışmanın gerçekleşmesi için BraTS 2015 ve 2017 görüntü verileri kullanılmıştır. %96.25'lik doğruluk oranıyla sınıflandırma performansı gerçekleştirmiştir [33]. KEK, en yakın eğitim verilerine dayanan özellik alanını kullanarak görüntüleri sınıflandırmak için bir yöntemdir [34]. Algoritma, yalnızca görüntülerin eğitimi için gerekli olan parametrelerin etiketlerini ve özellik vektörlerini saklar. Sınıflandırma görevinde, en yakın komşu, etiketlenmemiş sorgu noktasına atanır. Görüntünün sınıflandırılması, en yakın komşu etiketlerine göre yapılır. ESA'nın avantajları, ardışık katmanlar arasındaki nöronlar arasında seyrek bağlantı ve katmanlar arasında ağırlık paylaşımıdır. KEK, en yakın veri örneklerini benzer ölçülere göre bir sınıf olarak sınıflandırır [33].

Silva ve Welfer'in yaptığı çalışmada karakter çıkarım ve sığır markalaması sınıflandırması için hibrit DVM (Destek Vektör Makinesi)-ESA modeli geliştirilmiştir. Latin Amerika ülkeleri için sığır markalaşması hem ekonomik açıdan hem de sosyal açıdan çok önemli bir faaliyettir ve bu markalaşma için geliştirilen teknik bir araç mevcut değildir. Markalama işleminin manuel yapılması yeni gelen markaların kaydedilmesi işleminde zaman kaybına yol açmıştır. Bu zaman kaybının önüne geçmek için bilgisayar destekli hibrit bir sistem geliştirilmiştir. Hibrit model geliştirilirken ESA, görüntülerden özelliklerin çıkarımı için kullanılmıştır ve DVM'de görüntülerin eğitilmesi ve sınıflandırılması için kullanılmıştır. Eğitim sırasında ESA tarafından öğrenilen filtre seti, sorgu anında yeni görüntüdeki özellikleri tespit etmekten sorumludur. İlk filtre seviyesinde, bu tespit için kullanılan bazı çizgileri ve yönelimleri gözlemlenmiştir. Konolüsyon katmanında kullanılan 96 filtreyi temsil eden



96 ayrı set vardır. İlk evrişimden sonra yatay, düşey ve çapraz çıkıntılar gösteren alanların nasıl vurgulandığını gözlemlenmiştir [35]. Destek Vektör Makinesi, uygulamalarda kullanılan ve başarısı ile bilinen bir sınıflandırma algoritmasıdır. DVM ile belirli bir veri kümesindeki iki sınıfı özelliklerle ayırmak için en uygun alt düzlem sağlanabilir [36]. Farklı örnek setlere ait markalardan öznitelikler çıkarıldıktan sonra DVM ile sınıflandırıcı işlemi uygulanmıştır. İki sınıfın sınıflandırmasını temsil ettiği bir dizi örnek dikkate alınarak, yeni verilerin ait olduğu sınıfı öngörebilen ve ardından eğitim sürecini gerçekleştirebilen bir sınıflandırıcı yapılmıştır [35].

## 2.1. Kırık Tanımı

Kırık çıplak gözle görülemez ve bu nedenle onu tespit etmek için X-ışını, CT, ultrason, MRI görüntüleri kullanılır. Bu görüntüler doğrudan teşhis edilemez ve bu nedenle görüntü işleme, kırık tespitinde çok önemli bir rol oynar [37]. Kemikler, vücuda şekil veren, mekanik destek sağlayan, göğüs-karın bölgesindeki iç organları koruyan ve hareketi kolaylaştıran iskelet sisteminin organlarıdır. Ayrıca, vücudun mineral dengesine de katkıda bulunurlar [38]. Kemiğin yaklaşık % 20'si sudur ve kuru ağırlığın % 30-% 35'i organik ve % 65-70'i inorganik maddelerden oluşur. Kemik yapısında osteoblastlar, osteositler, osteoklastlar ve osteojenik öncü hücreler (mezenkimal osteoprogenitör hücreler) bulunur [38]. Osteoklastlar kemik rezorpsiyonu, osteoblastlar kemik oluşumu görevini üstlenir [39].

Kemikler sık sık kırılır ve bazı önemli kemiklerin kırılması bazı fonksiyonların yerine getirilememesine/işlevsel sınırlamalara ve sakatlıklara neden olur. Kırıklar meydana geldiğinde, iskelet dokusu organizasyonunda bir bozulma ve mekanik bütünlük kaybolur [40].

Kemik kırığı tespitinde önceki çalışma üç ana adımdan oluşur: (1) X-ışını görüntüleri denoize etme, (2) özellik çıkarma ve (3) görüntü sınıflandırma. Bu önceki çalışmaların bir ortak yanı, ya tek bir anatomik bölgeye ya da tek bir kırık tipine odaklanmış olmalarıdır, ör. tibia (açık kırık), kol ve femur boynu (ince kırık). Bu yöntem sadece kemik görüntüsünün kırılıp kırılmadığını algılayabilmiş, ancak kırık bölgesi

belirlenememiştir. Ancak pratikte uzman doktorların farklı anatomik bölümlerdeki kırığı tespit etmesi gerekmektedir. Bu nedenle, daha pratik bir sistem, insan vücudundaki farklı kemik türlerindeki kemik kırıklarını makul bir şekilde tespit etmede yardımcı olacaktır [41].

Görüntü işleme teknikleri çeşitli tıbbi alanlarda sıklıkla kullanılmaktadır. Dalgacık dönüşümü, tıbbi görüntü işleme alanında kullanılan uygulamalardan biridir. Bu uygulama tıbbi alanda önemlidir, çünkü dosya boyutundaki azalma, her disk miktarı veya bellek alanında daha fazla görüntünün depolanmasına izin verir. Bu tür görevler için, optimum ve en doğru sonuçlara ulaşmak için geri yayılım sinir ağı gibi yapay zeka araçları yardımıyla görüntü işleme teknikleri kullanılmıştır [42].

Geliştirilen sistem iki ana aşamadan oluşmaktadır. İlk aşamada, kırıkların görüntüleri, konumlarını ve şekillerini tespit etmek için farklı görüntü işleme teknikleri kullanılarak işlenir ve bir sonraki aşama, bir geri yayılım sinir ağının eğitildiği ve daha sonra işlenmiş görüntüler üzerinde test edildiği sınıflandırma aşamasıdır. Deneysel olarak, sistem farklı kemik kırığı görüntüleri üzerinde test edildi ve sonuçlar yüksek verimlilik ve bir sınıflandırma oranı gösterdi [42].

Bu çalışma, derin öğrenme algoritmasına ek olarak genetik algoritmaları (GA'lar) kullanması bakımından diğerlerinden farklıdır. Duyarlılık, özgüllük, doğruluk, F1 puanı ve Cohen'in kappa katsayısı açısından performans beş kat çapraz doğrulama testleri kullanılarak değerlendirilmiştir. En iyi performans, kırılan görüntüler 50x50 piksel olarak yeniden ölçeklendiğinde elde edilmiştir. Kappa metriği, ESA'yı beslemek için 50x50 piksel görüntü boyutu kullanıldığında daha güvenilir sınıflandırıcı performansı göstermiştir. Sınıflandırıcı performansı diğer görüntü boyutlarına göre daha güvenilir olduğu görülmüştür. Duyarlılık ve özgüllük oranları sırasıyla% 83 ve% 73 olarak hesaplanmıştır. GA'nın dahil edilmesiyle bu oran% 1,6 artmıştır. Kırık kemiklerin tespit oranı% 83 olarak bulunmuştur [43].

## 2.2. Kırığın Nedenleri

Kemik emilimi ve oluşumu arasındaki bir dengesizlik, osteoporoz dahil kemik hastalıklarının ve kırılmanın nedeni olabilir [39]. Kemik kırığı en yaygın sorundur ve kırılmadan en fazla etkilenen kemikler uzun olanlardır. Uzun kemikler fizyolojik ve fizyolojik olmayan kuvvetlere maruz kalır. Otomobil kazaları, travmatik olaylar, ateşli silah yaralanmaları, düşmeler, kemik erimesi, kemiklerle ilgili kanser gibi gibi durumlar nedeniyle ortaya [37,44]. Fizyolojik olmayan olağandışı durumlarda, stres koşulları ve sürekli baskı/basınç faktörleri altında kemik dokusunun direncinin azalmasıyla kırılma meydana gelir [38]. Kemiğin maruz kaldığı kuvvet kemiğin dayanım gücünü aştığında kırılma meydana gelir; güç zayıf olduğunda basit kırık gelişir. Fakat, genellikle kombine yük etkisine bağlı daha çok kompleks kırıklar meydana gelir [44]. Kırığa neden olan dış ve iç (intrinsik) faktörler söz konusudur.

### 2.2.1. Dış Nedenler

**Doğrudan Şiddet:** Travma, küçük hayvanlarda kırıkların en yaygın nedenidir ve genellikle otomobil yaralanması veya yüksekten düşme nedeniyle oluşur. Direkt travma nadiren kalibre edilmiş bir miktarda belirli bir yere iletiğinden, ortaya çıkan kırık nadiren tahmin edilebilir. Kuvvetin miktarı ve yönü kazadan kazaya değişecektir. Şiddetli doğrudan travmadan kaynaklanan çoğu kırık ya ufalanmış ya da çokludur [40].

**Dolaylı Şiddet:** Dolaylı travmaya bağlı kırıklar, doğrudan travmaya bağlı olanlara göre daha öngörülebilirdir. Genellikle bir kuvvet, kemiğe belirli bir şekilde ve kemik içindeki "zayıf bir bağlantıda" iletilerek kırılmaya neden olur [40].

**Bükülme Kuvvetleri:** Bükülme kırıkları, travmatik kuvvetin kemik diyafizinin elastik sınırını aştığı ölçüde, bir kemik üzerindeki belirli bir odak noktasına kuvvet uygulandığında meydana gelir. Bükme kırıklar genellikle eğik veya enine şeklindedir [40].

**Burulma Kuvvetleri:** Burulma kırıkları, bir kemiğin uzun eksenine bir bükme kuvveti uygulandığında meydana gelir. Kırık tipi, genellikle keskin uçlu ve çoğu kez keskin kenarlı uzun bir spiral şeklindedir. Yüksekten atlayan bir kedide hatalı atlayışa bağlı olarak tibial diyafizin spiral kırılması olguları görülür [40].

### 2.2.2. İç (İntrinsik) Nedenler

**Kas Hareketine Bağlı Kırıklar:** Bir kasın şiddetli kasılmasından kaynaklanan kırıklara avülsiyon kırıkları denir. Bu kırıklar sıklıkla gelişmekte olan hayvanlarda meydana gelir.

**Patolojik Kırıklar:** Bu tip kırıklarda altta yatan kemiğe veya sistemik bir hastalığa bağlı bir neden bulunmaktadır. Bu tip kırıklarda dışarıdan bir travmaya gerek yoktur. Hayvanın ağırlığı gibi faktörler bile kırılmaya neden olabilir [40].

### 2.3. Tibia Kemik Kırıkları

Tibia (**Hata! Başvuru kaynağı bulunamadı.**), bacağın en büyük ve medial kemiği veya arka ekstremitenin orta segmentidir. Proksimal yüzeyi, femur ile eklemlenen lateral ve medial kondilleri taşır. Yanal kondilin hemen distalinde, yan yüzeyde fibula başı için küçük ve neredeyse oval faset bulunur. Küçük bir kas olan popliteus çentikte yer alır ve diz ekleminin bir fleksörüdür. Tibial tepe, şaft boyunca yumru (tüber)'dan distal olarak devam eder. Tibianın distal ucunun iki eklem yüzeyi vardır [45].



Şekil 3.1 Farklı açılardan çekilmiş köpek (A) ve kedi (B) tibiası [46]

### 2.3.1. Köpek ve Kedilerde Tibia Kırıkları

Köpekler, evcil hayvan nüfusunun çoğunluğunu oluşturmaktadır. Bu evcil hayvanlar, sıklıkla travmatik yaralanmalardan veya kemik patolojisinden kaynaklanan apendiküler kemik kırıklarına eğilimlidir [47].

Tibia kırıkları köpek ve kedilerde, özellikle de yavru köpeklerde yaygın olarak karşılaşılan uzun kemiklerin ortopedik bir sorunudur [47,48]. Kırık kemik uçlarının gerekli şekilde kaynayamaması konusunda radiustan sonra en fazla kırılma oranına sahip kemik, tibia'dır. Uzun kemik kırıklarının % 20'sini oluşturan tibia kırıkları köpeklerde nispeten yaygındır. Tibia kırıkları, tibianın kranio-medial yönünü kaplayan çok az yumuşak doku olmasından dolayı çeşitli şekillerde görülebilir. Gençlerde daha çok ufalanmamış, veya tam olmayan kırıklar görülür; parçalı kırıklar ise esas olarak erişkinlerde görülmektedir. Yetişkinlerde ufalanmış kırık sıklığının temel sebebi yetişkin kemiğindeki artan kırılabilirlik ve bu tür kemiklerin verilen enerjiyi emme kapasitesindeki azalma ile ilgili olabileceği bildirilmektedir [47]. Tibianın kranio-medial yönünü kaplayan kas dokusunun çok az olmasından dolayı açık kırıklar daha yaygın görülür. Gerek açık kırıklar, gerekse veteriner hekimin teknik

uzmanlığındaki yetersizlikten ziyade, karar verme noktasındaki etersizliğine bağlı komplikasyonlar gelişebilir. Kırığın ameliyat öncesi değerlendirilmesi ve onarımın planlanması tibia kırıklarının komplikasyon oranlarını azaltmaya yardımcı olur [49].

Köpek ve kedilerde kırık tiplerini ve sıklığını belirlemek amacıyla yapılmış retrospektif (geriye dönük) çalışmalar bulunmaktadır. Indore'daki Teaching Veterinary Clinical Complex (T.V.C.C), Mhow ve Devlet hastanelerine getirilen vakalardan yapılan bir retrospektif çalışmada köpeklerde kırılma oranının % 1.14 olduğu, daha çok 1-6 aylıklarda ve çoğunlukla otomobil kazasına bağlı olduğu, kırığın daha çok femurda, bunu takiben tibia-fibula, radius-ulna ve humerus'ta görüldüğü bildirilmiştir [47]. Singh ve ark (2015) tarafından yapılan bir çalışmada T.V.C.C'e getirilen köpek, sığır, manda, keçi ve diğer türler kapsamında kırıklara en fazla rastlanan türün köpekler olduğu kaydedilmiştir. Büyüyen köpeklerde uzun kemik kırıklarının oluşumunu ve modelini ve İntramedüller (IM) Steinmann pin sabitlemesinin etkinliğini belirlemek için yapılan bir retrospektif (geriye dönük) çalışmada 10 yıllık bir süre boyunca büyüyen köpeklerin tüm kayıtları, travmanın nedenini, hayvanın yaşı ve cinsiyeti, dahil olan kemik, kırığın türü ve yeri, fiksasyon durumu, hizalama ve bakımını yönünden inceleme yapılmıştır. Araştırma sonunda 310 kırık vakasının 91'inde (% 29) kemiklerin osteopenik olduğu belirlenmiştir [44]. Osteopeni (% 25) olan köpeklerde kırılmanın başlıca nedeni küçük travmalar olduğu ve en yaygın olarak etkilenen ırkın ise yerli ırklar (% 38) olduğu, osteopenik kemikli köpeklerde kırıkların en yaygın olarak 2-4 aylık yaş grubunda (% 53) kaydedildiği bildirilmiştir. Normal köpeklerde ise kırıkların 2-8 aylık arasında dağıldığı, erkek köpeklerin her iki grupta da en fazla etkilenen cinsiyet grubu olduğu bildirilmiştir [50]. 2005'ten 2010'a kadar küçük hayvanlarda (köpekler ve kediler) kırıkların oluşumunu ve modelini kaydetmek için yapılan bir retrospektif çalışma yapılmıştır. Küçük hayvan cerrahisi ünitesine gelen toplam 650 vaka'nın 116'sının köpek ve kedilerde farklı kemik kırıkları olduğu bildirilmiştir. Bu 116 vakanın % 67'si köpek, % 23'ü kediler ile ilgili bildirilmiştir. Hayvanlarda kırıkların nedeni köpeklerde çoğunlukla kaza, kedilerde ise yüksekte düşme olarak ve yaşlar da köpeklerde 4 ay-12 yıl yaş, kedilerde 4 hafta-10 yıl yaş arasında değiştiği ve Femur kırıklarının köpek ve kedilerde sırasıyla % 37.5 ve % 25; tibial kırık ise sırasıyla % 21.5 ve % 10 olarak bildirilmiştir [51]. Kore'de 2005-2011 arası kapsayacak şekilde yapılan bir retrospektif çalışmada

da kırıkların özellikle Yorkshire terrier (%12), Poodle (%12), ve Maltese (%9) gibi minyatür köpeklerde görüldüğü, vakalarını %50'sinin 1 yaştan küçük ve daha çok erkek köpeklerde (%54) olduğu, kırıkların yazın ve trafik kazası şeklinde görüldüğü, kemik kırıklarının en fazla femur (19), bunu hemen takiben tibia/fibula (15) da olduğu bildirilmiştir

### **2.3.2. Kırıkların Klinik ve Doğrulayıcı Tanı Yöntemleri**

Herhangi bir tedavinin başarılı ya da başarısız sonucu, büyük ölçüde sorunun ne kadar doğru şekilde tespit edildiğine bağlıdır [52]. İskelet sisteminin radyografik görüntülemesi, küçük hayvan ortopedi biliminin ayrılmaz bir parçasıdır. Ancak tanı için radyografilerin tek başına incelenmemesi, olgunun arkasındaki geçmişin anlaşılması, eksiksiz bir fiziksel ve kapsamlı ortopedik muayenenin sonuçları dikkate alınarak tüm hasta bağlamında değerlendirme yapılmalıdır. Dikkatli bir sistematik yaklaşım, hatalardan kaçınmaya yardımcı olur (örneğin, patolojik bir kırığı kaçırmak veya bariz bir açık uç uzuv kırığını ve uzuvda başka bir yerde kapalı bir proksimal kırığı kaçırmak) ve komplikasyonların erken tespitini sağlayarak istenmeyen bir durumu önlemek için hızlı müdahaleyi mümkün kılar [53].

Kırıklarda erken teşhis ve doğru sınıflandırma, tedavi yönteminin seçiminde çok önemlidir [48]. İnsanlarda yanlış tanı konulan kırıklar, Acil Servislerde (ED'ler) tüm acil servise gelenlerin yaklaşık % 1'inde meydana gelen tanı hatalarının önde gelen nedenidir. Gözden kaçan kırıklar, hekimler tarafından kas-iskelet radyografilerinde yapılan en yaygın yorumlama hatası türüdür. Tedavide gecikmelere neden olabilirler, kötü kaynama ve artrite eşlik eden morbiditeye yol açabilir ve doktorlara karşı yanlış uygulama iddialarına yol açan en yaygın faktörlerden biridir. Kırıkları radyografilerde güvenilir bir şekilde tanımlamak zordur çünkü kırıklar benzersiz şekilde heterojendir: herhangi bir kemikte ortaya çıkabilir ve görünüşleri bölgesel anatomiye ve radyografik projeksiyona bağlıdır. Kas iskelet sistemi görüntülemeye uzmanlaşmamış klinisyenler, genellikle birçok farklı ve genellikle çözümü zor sunumlarında kırıkları tanımlama konusunda sınırlı eğitime sahiptir[54].

Klinik anormalliklerin tanısında ekran filmi görüntülerinin ve düşük kaliteli floroskopik tanı yöntemlerinin yeterliliği daima sorgulanmıştır. Radyologlar tarafından % 30 gibi yüksek oranda lezyonların gözden kaçırıldığı ve bunun da çoğunlukla gözlemciler arası varyasyonlardan ileri geldiği bildirilmiştir. Bu tür sorunlardan kaçınmak için son derece hassas ve gelişmiş görüntüleme tekniklerine ihtiyaç olduğu anlaşılacak şekilde günümüzde dijitalleştirilmiş sisteme sahip modern teşhis yöntemleri geliştirilmiştir. Ancak, Bilgisayarlı Tomografi (BT) gibi modern tanı yöntemleriyle bile farklı lezyon türlerinin sıklıkla gözden kaçırılabilirdiği ve klinik tanısal görüntüleme tekniklerinde daha fazla ilerleme yapılması gerekliliği vurgulanmıştır [52]. Diğer yandan, deneyimli bir doktorun, röntgen görüntüsünde kemik kırığının nerede meydana geldiğini incelemek için çok zaman harcaması gerekir. Bununla birlikte, birçok hastanede bu tıbbi görüntülerle ilgilenecek deneyimli radyolog eksikliği vardır. Kemik kırığı tespitinde doktorlara yardımcı olmak için, bilgisayar destekli tanı (CAD) tıbbi görüntülerin analizinde yaygın olarak kullanılmakta ve bu yıllar içinde giderek bir artış görmektedir [41]

X ışınları gibi eski teknikler kemik kırıklarının tespitinde de halen popüler, verimli ve etkili bir şekilde kullanılmaktadır. Ancak, bazen kırıkların boyutu anlamlı olmadığında bu metotla kolayca tespit yapılamaz. Bu nedenle etkili ve akıllı sistemlerin tasarlanması gerekmektedir [42]. Özellikle tıbbi alanda olmak üzere, günümüzde pek çok farklı alanda her gün hızla gelişen yeni teknolojiler ortaya çıkmaktadır. Tıbbi görüntü işleme alanında derin öğrenme tekniklerinin kullanımı son yıllarda popülerlik kazanmıştır. Bilgisayarların çevresel faktörlerden etkilenmemesi, öğrendiklerini unutmaması ve sınırsız bellek kapasitesine sahip olması, doğruluk oranları iyileştirilirse algoritmaların yakın gelecekte hekimlerin hastalarına yönelik karar verme süreçlerini doğrudan etkileyeceğini düşündürmektedir. Derin öğrenme tekniklerini kullanma kırıkların erken teşhisi, tedaviye erken başlanması, ameliyat sonrası iyileşme süresinin kısaltılması ve yanlış teşhis nedeniyle artan maliyetleri de önleyerek yarar sağlayacaktır [43].

Son teknolojik tanısal görüntüleme tekniklerinin çoğu tıp alanında uzun yıllardır kullanılmaktadır. Ancak, veteriner pratikte tanısal görüntüleme için yeni yöntemlerin geliştirilmesi ve tanıtılması oldukça yenidir [52].



## 2.4. Yapay Zeka (YZ)

YZ, sensörleri aracılığıyla çevresini algılayan, etkileşime giren ve başarı şansını en üst düzeye çıkarmak için eylemler gerçekleştiren akıllı unsurların çalışması ve tasarımı ile ilgilenen bir bilgisayar bilimi dalıdır [55,56]. Basitçe YZ, makinelere insan gibi düşünme yeteneği kazandırma işlemidir [57]. Böyle bir işlem insan beyninin öğrenme metodunu taklit etmeye çalışan öğrenme algoritmaları yoluyla mümkün olabilmektedir. Nitekim günümüzde bu öğrenme algortimalarından günlük yaşantının farklı alanlarında yararlanılmaktadır [56]. YZ, günümüz bilgisayar yazılımının durumunu ifade eden ve belli görevleri yapan dar/zayıf YZ, bir bilgisayarın akıl yürütme, planlama, problem çözme, soyut düşünme, karmaşık fikirleri anlama, hızlı öğrenme ve deneyimlerden öğrenme dahil olmak üzere hemen hemen her alanda bir insanın zeka düzeyine eşit olmasıyla ulaşılan yapay zeka düzeyini karşılayan yapay genel zeka (YGZ), bir insanın zeka seviyesini katlayarak birkaç büyüklük derecesiyle aştığında ulaşılan yapay zeka seviyesini karşılayan yapay süper zeka (YSZ) şeklinde tiplendirilmektedir [58,59].

YZ terimi 1956 yılında John McCarthy tarafından geliştirilmiştir. John McCarthy YZ'yi "akıllı makineler yapma bilimi ve mühendisliği" olarak tanımlamıştır. Ayrıca, YZ "aynı anda iki farklı fikri akılda tutma ve fonksiyon için yeteneğinin hala devam ediyor olması" şeklinde de tanımlanabilmektedir [55]. Daha geniş olarak ise YZ "bir sistemin harici verileri doğru şekilde yorumlaması, bu tür verilerden öğrenme ve bu öğrenmeleri esnek adaptasyon yoluyla belirli hedeflere ve görevlere ulaşmak için kullanma yeteneği" şeklinde de tanımlanmaktadır [60]. Yapay zeka geçmiş deneyimlerden öğrenme, karar verme mantığı, çıkarım gücü ve hızlı cevap özelliklerini içermeli, karmaşıklık ve belirsizlikle başa çıkabilmelidir [55]. YZ güvenlik, araştırma, robotik, ses tanıma, ulaşım ve daha pek çok alanda başarılı olduğu kanıtlanan sinir ağları, derin öğrenme, istatistik, makine öğrenmesi gibi diğer pek çok alanı içerir ve bu haliyle sadece insanların iş yükünü azaltmakla kalmaz, aynı zamanda hayali kurulan yeni alanlar da açar [57].

İngiliz matematikçi Alan Turing İkinci Dünya Savaşında Alman ordusu tarafından kullanılan Enigma kodunu çözmek amacıyla İngiliz hükümeti için yaklaşık 7x6x2 fit genişliğinde ve yaklaşık 1 ton ağırlığında, ilk çalışan elektro-mekanik bilgisayar olarak kabul edilen “Bombe” adlı bir kod kırma makinesi geliştirmiştir. Bu makinenin böyle bir kodu çözebilmesi, Alan Turing’i makinelerin zekası konusunda meraklandırmış ve 1950’de akıllı makinelerin nasıl oluşturulacağı ve zekalarının nasıl test edileceği konusunda bilgi verdiği “Bilgisayar ve Zekası” adlı makalesini hazırlamaya yönlendirmiştir. Makalede yapay bir sistemin zekasını belirlemek için ölçüt olarak kullanılan “Bir insan başka bir insanla ve bir makineyle etkileşim halindeyse ve makineyi insandan ayırt edemiyorsa, makinenin akıllı olduğu söylenir” kriteri bugün hala kullanılan “Turing Testi” olarak bilinir. Bu süreçten 6 yıl sonra “Yapay Zeka” ifadesi resmen ortaya atıldı. Ancak, 1970’lerde ABD ve İngiltere gibi ülkelerde yapay zeka araştırmaları üzerine yapılan araştırmalar ve ayrılan fonlar oldukça eleştirildiğinden bu alanda bir durgunluk dönemi yaşanmıştır. Sadece Japonya 1980’de bu alana daha fazla fon ayırmıştır. 1997’de dünya şampiyonu ünlü satranççı Gary Kasparov’u yenmeyi başaran IBM’in Deep Blue satranç oynama programının saniyede 200 milyon olası hareketi işleyebildiği ve “ağaç arama” adı verilen bir yöntemi kullanarak 20 hamle ileriye bakarak bir sonraki en uygun hareketi belirleyebildiği bildirilmiştir. Ancak, uzman sistem olarak adlandırılan böyle bir sistem gerçek yapay zeka olamadığından yüzleri tanımak, bir çörek ile bir tür köpeği resimden ayırmak konularında iyi performans gösterememektedir. Bu tip fonksiyonlar için bir sistemin dış verileri doğru şekilde yorumlayabilmesi, verilerden öğrenebilmesi ve bu öğrenmeleri yapay zekayı tanımlayan özellikler olan esnek adaptasyon yoluyla belirli hedeflere ve görevlere ulaşmak için kullanabilmesi gerekmektedir. Google tarafından geliştirilen bir program olan AlphaGo, 2015 yılında Go tahta oyununda dünya şampiyonunu yenmeyi başardığında Derin Öğrenme biçiminde bir geri dönüş yapmıştır. Bugün yapay sinir ağları ve Derin Öğrenme, YZ etiketi altında bildiğimiz çoğu uygulamanın temelini oluşturmaktadır [60].

1950’lerde akademik bir disiplin olarak kurulan YZ, yarım yüzyıldan fazla bir süre göreceli bilimsel belirsizlik ve sınırlı uygulama alanı olarak kalmışken, günümüzde büyük veri artışları ve bilgi işlem gücündeki artışlar nedeniyle iş ortamı ve kamusal alana girmiştir. Yapay zeka sergilediği zeka türlerine göre analitik, insandan

esinlenilmiş ve insanlaştırılmış olarak veya gelişme aşamasına göre yapay dar, genel ve süper zeka olarak sınıflandırılabilir [60]. YZ ile ilgili bilgisayar sistemleri günümüzde büyük veri olarak bilinen büyük veri kümeleri içindeki karmaşık doğrusal olmayan ilişkileri tanımlamak için birden fazla algoritma kullanan esnek matematiksel modeller olan yapay sinir ağlarına dayanır [10]. Dolayısıyla, YZ elementleri insan elementi, bilgi tabanı ve algoritma setinden, bileşenleri ise öğrenme, problem çözme, mantık ve akıl yürütme, algı, dil-anlama, sinir ağı ve makine öğrenmeden oluşur. Sektörleri ise genetik programlama, veri madenciliği, model tanıma ve uzman sistemden oluşur [55,57]. Yapay zeka alanında iki temel yaklaşım söz konusudur. Bunlardan ilki bilgi mühendisliği sistemleri, mantık programlama ve mantıksal muhakemeye dayanır. İkincisi ise mikroskobik biyolojik modelleri kapsar. Yapay sinir ağları (YSA; Artificial Neural Network-ANN) ve genetik algoritmalar ikinci yaklaşımın örneğidir. Matematiksel olarak bir YSA, her düğümün (node) bir nöron modelini uyguladığı doğrudan bir grafik olarak ifade edilebilir [61].

#### **2.4.1. Yapay Zeka Bileşenleri**

##### **2.4.1.1. İnsan Unsuru**

Bu, insan ile makine arasındaki bir bağlantıyı ifade eder. Makine veya basitçe bir algoritma, insanlar tarafından anlaşılması ve işlenmesi zor olan 0 ve 1'lerin dilini anlar. Böylece, kullanıcıdan yön alabilen, işleyebilen ve daha sonra doğru sonuçlar veren etkileşimli bir arayüz rolü vardır [57].

##### **2.4.1.2. Bilgi Tabanı**

YZ, içinde bulunan verileri analiz etmeye çalışır. Ne kadar çok veri beslenirse, o kadar verimli sonuç sağlayacaktır. Bilgi tabanı ayrıca bazı kalıpları incelemek ve aramak için önceki sonuçları da içerir. YZ, verileri analiz eder, işler ve en iyi sonuçları sağlamak için büyük bilgi yığınlarını karşılaştırır. Mevcut soruna bir çözüm bulmak için veri algoritmalarını ve depolanan çeşitli diğer mantıkları kullanır [57].

### **2.4.1.3. Algoritma Seti**

YZ arayüzü, büyük miktarda veri ile beslenmesine rağmen, bu verileri işlemek ve gerçekleştirmek için belirli bir talimat seti veya algoritma gerektirir. Bu tür algoritmalar, istatistik, olasılık, hesap ve cebir gibi çeşitli matematiksel araçları kullanarak birlikte çalışan programcılar ve veri bilimcileri tarafından sağlanır [57].

Bulanık mantık yapay zekanın küçük bir bölümüdür. Bulanık mantık problem çözmeye matematiksel bir yaklaşımdır. Bulanık mantık ABD’de icat edilmiş ve gelişmesi Japonya’dan başlamıştır. 1960’da Dr. Lotfi Zadeh tarafından doğal dilin belirsizliğini modellemek için bir araç olarak tanıtılmış ve iki değerli mantık kuramlarına bir alternatif oluşturmuştur [55]. Ancak, "Bulanık" sözcüğünün mantık bilimiyle ilişkilendirilmesindeki zorluk nedeniyle, başlangıçta Zadeh tarafından ortaya atılan bu kuramla ilgili olarak “mantığın bulanık olanı da mı olurmuş” şeklinde eleştiriler gelmiştir [62].

İnsan beyni belirsizlikler ve yargılar üzerinden akıl yürütebilirken, bilgisayarlar sadece kesin değerleri değiştirebilir. Bulanık mantık bu iki tekniği birleştirme girişimidir [55,62]. Bulanık mantık metro sistemleri, çamaşır makinesi gibi ev aletlerinin (deterjan miktarı veya çamaşır yükü gibi yönlerden) kontrolü, teşhis sistemleri gibi alanlarda çok yararlı özellikleri olduğundan üretim süreçlerinde oldukça kullanışlıdır. Geleneksel mantıkta bir nesne sıfır veya bir değerini alır, ancak bulanık mantıkta bir nesne 0 ile 1 arasında herhangi bir gerçek değeri alabilir. Bulanık mantıkla nöral network’lerin kombinasyonunu kullanır [55].

## **2.4.2. Yapay Zeka Sektörleri**

### **2.4.2.1. Genetik Programlama**

Tıpkı insanların evrimleştiği gibi, en uygun genler de insan ırkını evrimleştirmek için birçok nesil boyunca mutasyona uğradı. Benzer şekilde, insan evriminden esinlenerek, genetik programlama, kullanıcı tanımlı görev için bir çözüm bulmak için birden fazla nesil boyunca rastgele mutasyon, geçişler gerçekleştiren bir algoritma yürütür [57].

#### **2.4.2.2. Veri Madenciliği**

Veri madenciliği, verilerdeki kalıpları veya eğilimleri arayan, filtreleyen ve temiz bir yararlı set getiren YZ algoritmalarının yardımıyla büyük bir ham verinin yararlı bir bilgi kümesine dönüştürüldüğü bir süreçtir [57].

#### **2.4.2.3. Örüntü Tanıma**

Örüntü tanıma, daha önce elde edilen bilgilere veya verilerde bulunan belirli kalıplara dayalı istatistiksel kayıtlara göre büyük veri tabanlarını sınıflandırmak ve sıralamak için bir makine öğrenme algoritmasının kullanıldığı bir işlemdir [57].

#### **2.4.2.4. Uzman Sistem**

Uzman sistem, bir insan uzmanın karar verme yeteneğini simüle eden makine sistemidir. Bu sistemler, karmaşık kararlar almak, uzmanların karmaşık akıl yürütme algoritması yoluyla hareket edeceği şekilde hareket etmek, akıllı tavsiyelerde bulunmak, kararlar veya talepler hakkında açıklamalar yapmak ve gerekçeler sunmak için tasarlanmıştır [55,57]. Uzman sistemler, belirli bir alan hakkında iyi tanımlanmış uzmanlık bilgilerinden oluşan geniş bir veritabanına dayanmaktadır. MYCIN, TURNX, PROSPECTOR gibi uzmanlık eğitimi, tasarım ve sorun giderme vb. İçin tasarlanmış birçok uzman sistem mevcuttur. Yapılandırılmamış bir dizi LISP işlevinden oluşan ve çeşitli sembolik matematiksel görevleri yerine getiren MACSYMA en eski uzman sistemlerden biridir [55].

Uzman sistemlerin insanlardan daha iyi iş çıkarması, daha az hata yapması, insan uzmanlığına göre daha ucuz olması, belirli bir alandaki benzersiz becerilere iyi bir şekilde konsantre olabilmeleri için uzmanların mekanik türde tekrarlayan görevlerini yerine getirebilme yetisine sahip olmaları, pekçok yöneticinin karar stiliyle uyumlu olmaları, insanlar için uygun olmayan ortamlarda işlem yapılmasını sağlayabilmeleri ve sanayinin üretkenliğini artırmaları gibi yararlı yönleri vardır [55].

## 2.5. Makine Öğrenmesi

Bir YZ programı “Akıllı Ajan” olarak adlandırdığından çevre ile etkileşime girer. Bu ajan sensörleri aracılığıyla bir ortamın durumunu belirleyebilir ve ardından aktüatörleri aracılığıyla durumu etkileyebilir. YZ'nin nihai amacı, makinelerde insan benzeri zeka geliştirmektir. Böyle bir geliştirme, insan beyninin nasıl öğrendiğini taklit etmeye çalışan öğrenme algoritmaları yoluyla gerçekleştirilebilir. YZ'nin makine öğrenmesi-MÖ (denetimli, denetimsiz, pekiştirmeli), doğal dil işlemesi-DDİ (içerik ekstraksiyonu, klasifikasyon, makine çevirisi, soru cevaplama, metin oluşturma), uzman sistem, vision (görüntü tanıma, makine vizyonu), konuşma (metinden okumaya, okumadan metne), planlama, robotikler gibi alt dalları vardır ) [63].

Makine Öğrenimi, verilerden belirli kalıpları analiz ederek, anlayarak ve tanıyarak bilgi veya beceri edinmeyle ilişkili bir YZbölümüdür [63]. Makine öğrenimi, yapay zeka (YZ) alanındaki en heyecan verici teknolojilerden biridir. Dama oyun programısıyla ünlü Arthur Samuel'e göre makine öğrenimi, bilgisayarlara açıkça programlanmadan öğrenme yeteneği veren çalışma alanıdır. Arthur, programı geliştirdiğinde başlangıçta oyunda daha başarılı iken zaman içerisinde sistemin iyi ve kötü pozisyonları daha iyi öğrenerek kendisine karşı daha başarılı olduğunu gözlemlemiştir. Tom Mitchell ise konuyu daha profesyonelce izah ederek, bir bilgisayar programının bazı görevler (Task-T) ve performans ölçütleri (Performance-P) üzerinden deneyimle (Experience-E) öğrendiğini ifade etmiştir [56].

Makine öğrenmesi, veri içeren bir modelleme tekniğidir. Makine öğrenmesi bilgisayarların veri birikiminden otomatik olarak öğrendiği bir yapay zeka alanını tanımlamak için 1959'da Arthur Samuel tarafından ortaya atılmış bir terimdir ve büyük veri analizi için kapsamlı bir şekilde uygulanmıştır [10]. Makine öğrenmesi Yapay Zeka çağının popüler bir konusudur. Bilgisayar görüşü ve Doğal Dil İşleme alanları, hiç kimsenin tahmin edemeyeceği atılımlar yapmaktadır. Her ikisi de akıllı telefonlarda yüz tanıma, dil çeviri yazılımı, sürücüsüz arabalar vb. gibi uygulamalarla günlük yaşantıda giderek daha fazla görülmektedir. Yani bu uygulamalarla bilim kurgu gibi görünebilecek şeyler gerçek olmaktadır. Makine öğrenmesi günümüzde tıbbi teşhis ve tedaviden sosyal ağlarda arkadaşları bulmaya kadar pek çok alanda

birçok ticari uygulamanın ve araştırma projesinin ayrılmaz bir parçası haline gelmiştir. Pek çok insan, makine öğrenmesinin yalnızca kapsamlı araştırma ekiplerine sahip büyük şirketler tarafından uygulanabileceğini düşünmektedir. Makine öğrenmesinin uygulamaları mevcut veri miktarı ve hayal gücüyle sınırlı olacak şekilde sonsuz gözükmemektedir [64].

### **2.5.1. Makine Öğrenme Algoritmaları**

Makine öğreniminde analizde dikkate alınan özelliklerin çoğunun, kalıpları daha kolay görünür hale getirmek için bir uzman tarafından manuel olarak seçilmesi gerekmektedir. Derin öğrenme algoritmaları, yüksek seviyeli özelliklerden aşamalı olarak öğrenir. Makine öğrenimi algoritmalarında algoritmayı eğitmek birkaç saat kadar sürer. Derin öğrenme algoritmaları çok büyük miktarda verili problemler için uygun olduğundan algoritmayı eğitmek daha uzun sürer, fakat test aşamasında derin öğrenme algoritmalarının çalışması daha az zaman alır [63].

Makine öğrenmesi algoritmalarının denetimli, denetimsiz, takviyeli/pekiştirmeli ve öneri sistemleri gibi tipleri vardır. Denetimli makine öğrenmesi hesaplanan çıktı ile beklenen çıktının karşılaştırılmasına dayanmaktadır [56]. Denetimli öğrenme etiketli bir veri yığınının eğitim ve test kümesi oluşturularak eğitim kümesi üzerinden bir model oluşturmak, modelin performansını test kümesi üzerinden incelemeye dayanmaktadır. Böylece yeni gelen etiketsiz örnekler model yardımıyla tahmin edilebilir hale gelmektedir [65]. Diğer bir ifadeyle denetimli makine öğrenimi, gelecekteki örneklerin kaderini tahmin etmek için harici olarak sağlanan örnekleri kullanarak genel kalıplar ve hipotezler üretebilen algoritmaların oluşturulmasıdır [66]. Denetimsiz makine öğrenmesi ise girdi modeline göre keşfederek ve benimseyerek kendi başına öğrenme olarak tanımlanır. Bu öğrenmede veriler farklı kümelerle bölünür ve bu nedenle öğrenmeye kümeleme algoritması da denir. Takviyeli öğrenme, sayısal bir ödül kavramını en üst düzeye çıkarmak için ne yapılacağını-durumları eylemlerle nasıl eşleştirileceğini öğrenmeye dayanır. Doğru çıktı için bir ödül ve yanlış çıktı için bir ceza verilir [56]. Takviyeli öğrenme, öğrenme yöntemlerini karakterize eden değil, bir öğrenme problemini karakterize eden olarak tanımlanır [65]. Takviyeli öğrenme, doğru girdi/çıktı çiftlerinin asla sunulmaması veya optimal altı eylemlerin açıkça

düzeltilmesi nedeniyle denetimli öğrenme probleminden farklıdır [56]. Ayrıca, denetimsiz öğrenmede de etiketlenmemiş veri koleksiyonlarında gizli olan yapı bulunduğu için takviyeli öğrenme denetimsiz öğrenmeden de farklıdır. Takviyeli öğrenme sisteminin dört ana alt ögesi vardır; bir politika, bir ödül sinyali, bir değer işlevi ve isteğe bağlı olarak bir ortam modeli şeklindedir [65].

### **2.5.2. Makine Öğrenmede Kullanılan Modeller ve Diller**


En küçük kareler vektör regresyonunu (EKVR), sınıflandırma ve regresyon ağacını (SRA), genel regresyon sinir ağlarını (GRSA) ve geri yayılım sinir ağlarını (GYSA) destekliyor [67].

Python, veri bilimcileri ve makine öğrenmesi geliştiricilerinin %57'si bunu kullanmaktadır. Bunu C/C++ (kullanımda %44), R (kullanımda %31), Java, JavaScript takip etmektedir. Diğerleri Julia, Scala, Ruby, Octave, MATLAB ve SAS'dır. Fakat bunların kullanımı öncelik sıralamasında % 5'in altında, kullanımda ise % 26'nın altındadır [64-48].

### **2.6. Yapay Sinir Ağları (YSA)**

Derin Sinir Ağı terimi çok katmanlı YSA'ları ifade eder [68]. YSA'ları yaklaşık 1950'lerden beri kullanılırken, derin öğrenme sinir ağları 2006 civarında başladı [69]. YSA, çeşitli veri türleri üzerinde denetimli, yarı denetimli ve denetimsiz öğrenmeyi kullanma becerisi nedeniyle diğer MÖ algoritmalarına göre üstünlüğe sahiptir [63]. YSA, beynin oldukça karmaşık, doğrusal olmayan, paralel bir bilgi işleme sistemi gibi çalıştığı varsayılarak, beynin bir işlevi yerine getirme şeklinin taklit edilmesi üzerinden yapılandırılmıştır (Şekil 3.2) [57,61]. Bu sistem bir girdi alır, analiz eder ve sonuç olarak YSA'ya verir [63]. YSA çok sayıda veriyi işleyebilme özelliğinden dolayı son yıllarda çok popüler hale gelmiştir [68].






Şekil 3.2 Derin öğrenmeye temel oluşturan bir nöron hücresi [Esinlenildi;57]

## 2.7. Derin Öğrenme

Derin Öğrenme, YZ yöntemleri ailesindedir. Derin öğrenme, bir makine öğrenme tekniğidir (Şekil 3.3) [63].



Şekil 3.3 YZ, ML ve DL arasındaki ilişki [63]


Makine öğrenmesi alanında derin öğrenme görüntü işleme için oldukça umut verici bir yaklaşım olarak ortaya çıkmıştır. Bir görevi tamamlamak için özel talimatlar gerektiren yazılımın aksine, derin öğrenme, sistemin kalıpları bağımsız olarak tanımasına ve tahminlerde bulunmasına olanak tanımaktadır [10]. Büyük verilerin derin öğrenme modellemesi, web aramadan finansal teknoloji bankacılığına, kendi

kendine giden arabalardan yüz tanıma konularına ve tıbbi karar desteğine kadar tıp içinde ve dışında çeşitli alanlarda başarılı olduğu kanıtlanmış bir makine öğrenme tekniğidir ve modern toplum üzerinde büyük etkiler yaratmaktadır [9,10]. Kısaca, derin öğrenme, belirli tek görevleri yerine getirmenin aksine, yüksek düzeyde veri yorumları oluşturmak için birden çok işlem algoritması katmanını kullanan karmaşık bir hesaplama modelidir [9]. Derin öğrenmede çok katmanlı ve geleneksel makine öğrenimi algoritmalarına göre çok daha fazla veriye sahip derin sinir ağları uygulandığından daha büyük modellere ve daha fazla hesaplama gereksinimi vardır. Diğer yandan derin öğrenme algoritmalarının performansı, verilerin miktarı ve çeşitliliği ile doğru orantılıdır [63].

DÖ'nün temel avantajı ham girdi verilerinin ( otomatik özellik seçimi ve boyut azaltma gibi) hiyerarşik sunumu için otomatik kodlayıcıların kontrol edilemeyen (denetimsiz) eğitimi ve veri eksikliğini telafi eden aktarım öğrenimindeki birkaç son katmanın denetimli yeniden eğitimini kapsayan DSA katman gruplarının bağımsız eğitimi için sistematik bir yaklaşım olmasıdır. Ancak, önemli veri sınırlaması ve / veya aktarımlı öğrenme için ilgili sorunun olmaması, DSA tabanlı DÖ'nün avantajlarını büyük ölçüde azaltabilmektedir. İstatistik ve makine öğreniminde bireysel modellere göre çok daha iyi örneklem dışı performansa sahip tamamlayıcı temel model gruplarını (ensemble-ikiden fazla model kullanarak yeni ve güçlü bir tek bir model elde etmeye yarayan teknik) keşfetme yeteneğine sahip artırma/güçlendirici algoritmalar (boosting algorithm) ailesidir. Güçlendirme (Boosting) pek çok pratik uygulamada başarısı kanıtlanmış en güçlü makine öğrenimi yaklaşımlarından biridir. Hibrit yaklaşımlarının çoğunun amacı sadece birini seçmek yerine, artırma (güçlendirme) ve DSA'ların en iyi özelliklerini birleştirmeye çalışmaktadır [70].

DÖ algoritmaları tıpta fundal fotoğraflarda diyabetik retinopatinin, cilt fotoğraflarında malign melanomanın teşhisinde, hatta daha küçük veri setleriyle tüberküloz ve akut intrakranial anormallikler gibi olguların teşhisinde başarıyla kullanılmıştır [9]. En popüler DÖ algoritmaları; Evrimsel Sinir Ağları, Tekrarlayan Sinir Ağları, Uzun Kısa Süreli Bellek Ağları , Yığınlanmış Otomatik Kodlayıcılar, Derin Sinir Ağları, Derin Boltzman Makinesi, Derin İnanç Ağları'dır [63,69,71].

Derin öğrenme çok katmanlı yapay sinir ağlarının verimli bir şekilde eğitilmesi sonucu ortaya çıkan ve makine öğrenmesinin de kapsadığı yeni bir teknolojidir. YSA'da Öğretmenli Öğrenme modelinde de örnek olarak teşkil eden Evrişimsel Sinir Ağları mimarisi kullanılmaktadır. Konvolüsyon Sinir Ağları (diğer adıyla Evrişimsel Sinir Ağları) görüntü sınıflandırma ve nesne tespitinde önemli gelişmeler kaydetmektedir. Görüntü sınıflandırmaya göre nesne tespiti daha zor ve bunun çözümü için daha kompleks metotlar gerektirir. Bunun üzerine nesne tespitinin doğruluğunu artırabilmek için Bölgesel temelli Konvolüsyon Sinir Ağları (R-CNN) metodu geliştirilmiştir. Fakat bu metot ile ağın eğitiminin maliyetli olması ve çok uzun sürmesi R-CNN'in zayıf yanları olarak görülür [72]. R-CNN nesne önerisini gerçekleştirmek için SelectiveSearch algoritmasını kullanır. SelectiveSearch algoritması boundingbox (sınırlayıcı kutu) sayısını azaltmayı sağlar ve 2000 nesne önerisinde (objectproposal) bulunur. R-CNN'de yaşanan dezavantajları ortadan kaldırmak için Fast R-CNN metodu geliştirilmiştir. Fast R-CNN metodu ile geliştirilen bu ağda bütün görüntü üzerinde birkaç Konvolüsyon ve maksimum havuzlama katmanı, aktivasyon haritasını üretmek için işlenir. Aktivasyon haritasından sabit uzunlukta özellik vektörü çıkarabilmek için her bir nesne önerisine ilgi bölgesi (RoI) uygulanır Fast R-CNN'in hızı R-CNN'e göre daha hızlı olsa da bu metotta da bölge önerisi (regionproposal) için SelectiveSearch algoritması kullanılır [72]. Hem R-CNN'de hem de Fast R-CNN'de yavaşlığa sebep olan SelectiveSearch algoritmasınıyerine daha hızlı sinir ağına sahip olan Faster R-CNN metodu geliştirilmiştir. Faster R-CNN'in genel mimarisi Şekil 3.4'da verilmiştir [73].




Şekil 3.4 Faster R-CNN mimaris [73]

Faster R-CNN, iki büyük ağ kapsamında iki bölüme ayrılır. Bunlardan birincisi Regional Proposal Network ikincisi ise Fast R-CNN'dir [73].


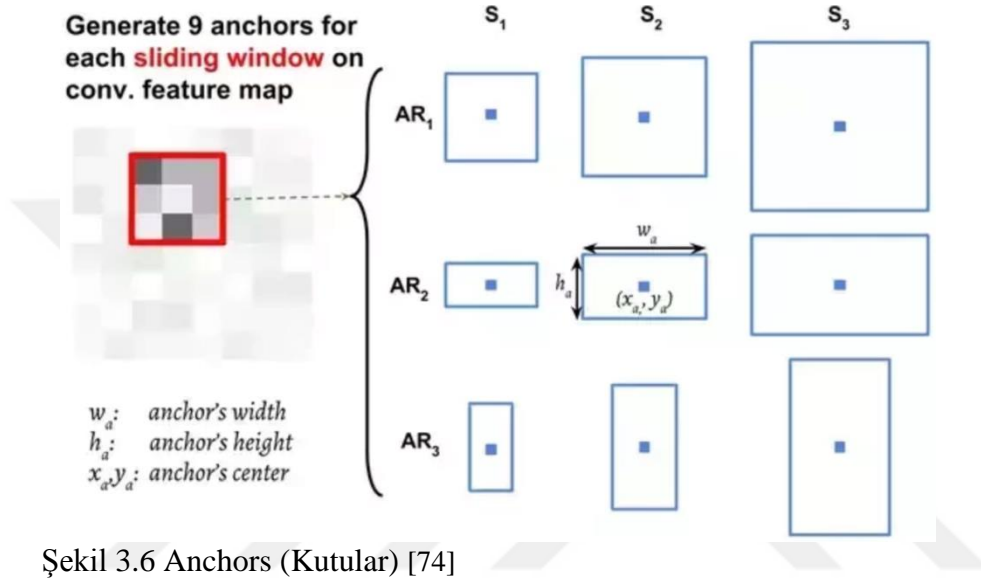
### 2.7.1. Regional Proposal Network (RPN)

Girdi görüntülerinden dikdörtgen kutu sınırlayıcıları olarak nesne önerileri kümesi çıktısı veren tam konvolüsyon ağıdır. RPN öncelikle ESA'dan Şekil 3.5'de görüldüğü üzere aktivasyon haritasını elde eder [74].



Şekil 3.5 Konvolüsyon Aktivasyon Haritası [74]

Daha sonra aktivasyon haritası üzerindeki her piksel için ReLU tarafından takip edilen bir başka konvolüsyon katmanına kaydırılır. Ön tanımlı referanslar olarak önerilen RoI, dikdörtgen kutuları (anchors) olarak adlandırılır ve her piksel üzerinde oluşturulur. Anchors'ın önerilen sayısı Şekil 3.6'de de görüldüğü üzere 9'dur [74]. Şekil 3.7'de de görüleceği üzere bu sayı üç farklı görüntü oranı (1:1,1:2,2:1) ve bir kutunun 3 renginin (kırmızı, yeşil ve mavi) genişliği ya da yüksekliğinin (128, 256, 512) kombinasyonudur [75].



Her anchor kutusu için görüntüdeki bir nesnenin kendisi ya da arka planının olma olasılığını 'de görüldüğü üzere softmax ve regresyon katmanları kullanılarak her pozisyonda obje skoru ile hesaplanır. Kutular ile kesin referans (groundtruth) kutu sınırlayıcılarının (boundingbox) ne kadar örtüştüğü IoU (Intersection over union) formül 2.1 ile hesaplanır [74]

Burada, IoU kesisim/bileşimdir ve aşağıda gösterilmiştir:

$$IoU = \frac{Anchor \cap GTBox}{Anchor \cup GTBox} \quad (2.1)$$

Şekil 3.6'de görüldüğü üzere konvolüsyon aktivasyon haritasından 3x3'lük konumsal özellik çıkarımı sınıflandırma ve regresyon özelliklerini içeren daha küçük katmanı (RPN) besler. Regresör'ün çıktısı boundingbox'ı belirler (x,y,w,h). Sınıflandırmanın çıktısı, **Hata! Başvuru kaynağı bulunamadı.**'de belirtildiği gibi p tahmin edilen kutu objeyi içeriyor mu yoksa içermiyor sonucunu verir [74].

### 2.7.2. Fast R-CNN

Girdi görüntüleri alınır ve ESA kullanılarak aktivasyon haritası çıkarılır. RPN tarafından önerilen bölgeler aktivasyon haritası üzerine bindirilir. Her bounding box sınırlayıcı kutu (bounding box) farklı boyutlarda olabilir. Tam bağlantılı katman sabit boyutta girdileri kabul eder. Bu durumu çözmek için RoI Pooling Katmanı, birkaç maksimum havuz operasyonu sabit uzunluktaki özellikteki vektörleri tam bağlantılı katmanı beslemek için RoI'den çıkarır. Her sınırlayıcı kutu için paralelde birbirini takip eden iki tam bağlantılı katman bulunur. Softmax katmanı sınıflandırıcı olarak çalışır. Regresyon katmanı bounding box'ın yeri ve alanını tanımlamak için 4 parametre çıktı verir [72].

## 2.8. Evrimsel Sinir Ağı

Nesne tanımaya yönelik mevcut yaklaşımlar makine öğrenme yöntemlerinden büyük ölçüde yararlanmaktadır. Daha büyük veri setleri toplanarak, daha güçlü modeller ve aşırı uyumu önleyen teknikler kullanılarak performans artırılabilir. Milyonlarca

görüntüden binlerce nesne hakkında bilgi edinebilmek için oldukça büyük öğrenme kapasitesine sahip bir modele ihtiyaç vardır. Nesne tanıma işlevi oldukça karmaşık olduğu için ImageNet ile bile üstesinden gelmek zor olacağından kullanılan modelin eksik verileri telafi etmek için çok sayıda ön bilgiye sahip olması gerekmektedir. Evrişimli sinir ağları (ESA'lar) böyle bir model sınıfını oluşturmaktadır [76]. En popüler sinir ağlarından biri ESA'dır [68]. ESA, makine öğrenme problemlerinde mükemmel bir performansa sahiptir. Özellikle en büyük görüntü sınıflandırma veri seti (Image Net), bilgisayarlı görü/görme ve doğal dil işleme gibi görüntü verileriyle ilgilenen uygulamalarda çok başarılı ve sonuçların da çok iyi olduğu kaydedilmiştir.

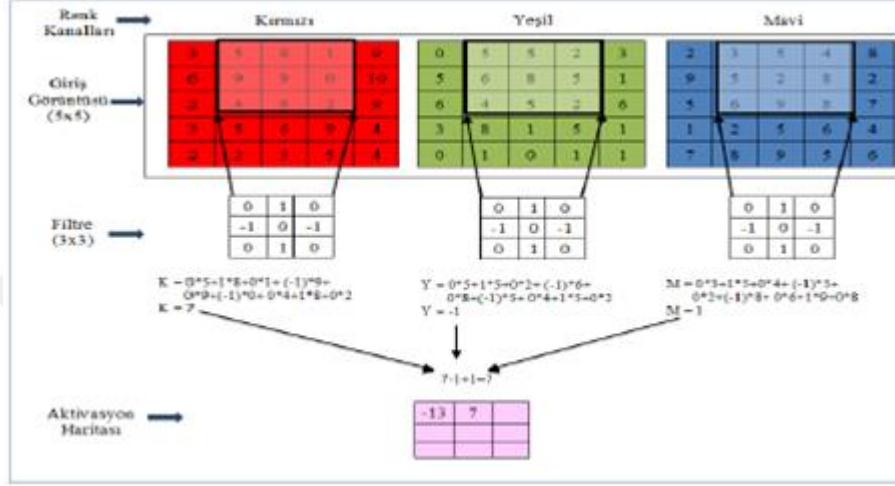
ESA'lar genellikle birkaç yazılım çerçevesinde kullanılır. Başlarda Caffe, Torch ve Theano gibi yazılımlar kullanılırken daha sonraları TensorFlow ve PyTorch gibi Python tabanlı olanlar popülerlik kazanmıştır. Keras veya Lasagne gibi üst düzey uygulama programlama arabirimi (API'ler), mevcut ağ mimarilerini ve önceden eğitilmiş ağırlıkları basitleştirerek DÖ sistemlerinin geliştirilmesini çok daha kolaylaştırmıştır [7].

ESA'ların en faydalı yönü YSA'daki parametre sayısını azaltmaktır. Bu da araştırmacı ve geliştiricileri klasik YSA'ları ile mümkün olmayan kompleks görevleri çözmek için daha büyük modelleri ele almaya teşvik eder [68]. Komplike özellikler ve fonksiyonları öğrenmek için üst düzey soyutlamaları temsil edebilen karmaşık özellikleri ve işlevleri öğrenmek için (vizyon, dil ve diğer yapay zeka düzeyindeki görevler gibi), YSA'ların derin mimarilere ihtiyacı vardır [61].

ESA adı, evrişim adı verilen matrisler arasındaki matematiksel lineer (doğrusal) işlemde gelmektedir. Genel olarak ESA, girdi katmanı, gizli katman (özellik çıkarma katmanları olarak da bilinir) ve çıktı katmanları şeklinde bölünür. Gizli katmanlar, evrişimli katman, doğrusal olmayan katman, havuzlama katmanı ve tamamen bağlantılı katman gibi çoklu katmanlardan oluşur ve katmanların sayısı farklı ESA'lar için farklılık gösterir [7,68]. Evrişimli ve tam bağlantılı katmanların parametreleri varken, havuzlama ve doğrusal olmayanların parametreleri yoktur [68].

## 2.8.1. Giriş Katmanı

ESA'nın ilk katmanını oluşturur. Veri bu katmanda ham olarak ağa verilir. Tasarlanacak modelin başarısında katmandaki verinin boyutu önem taşımaktadır [77]. Genişlik, yükseklik ve kanal sayısını belirtir. Genellikle 3 kanal - kırmızı, yeşil ve mavi (Şekil 3.8) [7,77].



Şekil 3.8 Filtrenin Uygulandığı Konvolüsyon İşlemi [77]

## 2.8.2. Evrişimsel Katman (Convolutional Layer)

Evrişimli katman bir ESA'nın temel yapı taşıdır ve giriş verilerini, özellik algılayıcıları olarak işlev gören bir dizi filtre (çekirdek olarak da bilinir) uygulayarak dönüştürür [68]. Filtre, bir özellik haritası (çıkıtı olarak) oluşturmak için giriş görüntüsünün üzerinde kayar. ESA, eğitim sürecinde bu filtrelerin ağırlıklarını öğrenir. Evrişim işlemlerinden sonra ReLU (formül 2.2) veya Doğrultulmuş Doğrusal Birim [7], Sigmoid (formül 2.3), tanh (formül 2.4) gibi [63] aktivasyon fonksiyonları adı verilen ek işlemler kullanılır.


$$\text{ReLU}(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (2.2)$$

$$S(x) = \frac{1}{1+e^{-x}} \quad (2.3)$$

$$\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$



Ağın girdi olarak ham pikseller alma durumunda giriş katmanını sadece bir nörona bağlamak için CIFAR-10 veri kümesi söz konusu ise ağırlık bağlantısı 32x32x3 olmalıdır (Şekil 3.9) [68].



Şekil 3.9 CIFAR-10 Veri Seti Ağırlık Bağlantısı [Esinlenildi;52]

Eğer gizli katmana bir nöron daha ilave edilirse diğer 32x32x3 ağırlık bağlantısı daha gerekecektir. Dolayısıyla toplamda 32x32x3x2 olacaktır. Yani girişi sadece iki düğüme (node) bağlamak için 6144 gibi ağırlık parametresi kullanılacaktır. Kimi zaman bir görüntü sınıflandırması için iki nöron yeterli olamayabilir, durumu daha etkili hale getirmek için aynı yükseklik, genişlik değerleri ile giriş görüntüsü sonraki katmandaki nörona bağlanabilir [68]

Adım (Stride) görüntü işlemede önemli bir kavramdır ve görüntü meta verilerinin basit bir şekilde değiştirilmesiyle sabit bir zamanda çok hızlı bir şekilde bir görüntü ile birkaç işlem yapılmasına izin verir. ESA parametreleri ve dolayısıyla olumsuz etkilere azaltmaya olanak sağlayan fırsatlar sunar. 7x7'lik bir görüntüde (Şekil 3.10) filtre her seferinde bir düğüm hareket ederse çıktı 5x5'e, 2 adım hareket ederse 3x3'e inecektir [68].



Şekil 3.10 Doldurma (Padding) [68]


Evrişimli fonksiyonu, biri ters çevrilip kaydırıldıktan sonra iki fonksiyonun çarpımının integrali olarak tanımlanır. Formül 2.5 ile ifade edilir.

$$\int_{-\infty}^{\infty} f(T) \cdot g(x - T) dT \quad (2.5)$$

### 2.8.3. Havuzlama Katmanı

Derin öğrenme modellerinde boyut küçültmek için kullanılan işlemdir. Havuzlamada, her bir özellik haritasının boyutsallığını azaltmak ve uzamsal olarak değişmez hale getirmek amaçlanır. Havuzlama maksimum, ortalama ve minimum şeklinde çeşitlere ayrılır. Evrişimli ve havuz katmanlarından elde edilen çıktı, giriş görüntüsünün üst düzey özelliklerini temsil eder [7,68].

Maksimum havuzlamada düzeltilmiş özellik haritasından en büyük eleman/değer alınarak yapılır (Şekil 3.11) [7,68].



Şekil 3.11 Maksimum Havuzlama Gösterimi [68]

Aynı renkli kutularda en yüksek değer alınarak (2x2'lik filtre ve 2 adım değeri kullanılarak) son 2x2'lik çıktı elde edilmiştir.

### 2.8.4. Seyreltme Katmanı

ESA'da büyük veriler ile eğitim işlemi yapıldığı için bazen ağ ezberleme yapar. Ağın ezberlemesinin önüne geçmek için bu katman kullanılır. Amaç, ağın bazı düğümlerinin kaldırılmasıdır [77].

### 2.8.5. Tamamen Bağlı Katmanı


Tamamen bağlantılı katmanın amacı, giriş görüntüsünü eğitim veri setine dayalı olarak çeşitli sınıflara sınıflandırmak için bu üst düzey özellikleri kullanmaktır. Bunun

ardından, ağ ağırlıklarını hesaplamak için geri yayılım gerçekleştirilir ve çıkış hatasını en aza indirmek için tüm filtreleri ve parametre değerlerini güncellemek için gradyan inişi kullanılır. Bu süreç eğitim sürecinde birçok kez tekrarlanacaktır [7].

## 2.9. Popüler ESA Mimarileri/Derin Öğrenme Modelleri

### 2.9.1. LeNet


LeNet, evrişim, havuzlama ve tamamen bağlantılı katmanların kullanımını kullanan klasik bir evrişimli sinir ağıdır. MNIST veri seti ile el yazısı rakam tanıma görevi için kullanılmıştır. Bu veri kümesi, 28x28 çözünürlüğe sahip 70.000 gri ölçekli görüntüden oluşur. Bunlardan 60.000'i eğitim ve 10.000'i test amaçlıdır. Her biri sıfırdan dokuza farklı el yazısı rakamları olan ve sınıf başına 7.000 görüntü içeren on sınıf vardır. Caffe paketinde sağlanan MNIST sınıflandırması için standart ağ mimarisi, 2 evrişimli / maksimum havuzlama katmanından ve ardından 2 tam bağlantılı katmandan oluşan 4 katmanlı LeNet'tir [78]. Bu model en eski modellerden biridir (1998) ve başlangıçta rakam tanıma için yaratılmıştır. Bir LeNet ağının genel yapısı, bir dizi tekrarlanan bloktan oluşur. Her blok, evrişimli bir katman ve ardından bir havuzlama katmanı içerir. Kullanılan uygulamada her blok bir ReLU (Rectified Linear Unit) katmanı ile sonlandırılır. Tekrarlanan blokların ardından, kullanılan ağ, havuzlama katmanı olmadan benzer bir blok içerir. Ağ, tamamen bağlı bir katman ve bir softmax katmanı ile sonlandırılır [79]. LeNet mimarisi Şekil 3.12'da gösterilmiştir [80].



Şekil 3.12 LeNet Mimarisi Gösterimi [80]

## 2.9.2. AlexNet

2012 yılında ilk olarak tanımlanan ESA'dır ve yaygın olarak kullanılmıştır [7]. AlexNet mimarisindeki ağ, ağırlıkları ile 8 katman içermektedir. İlk 5 katman konvolüsyonel kalan 3 katman ise tamamen bağlı katman içermektedir. İkinci, dördüncü ve beşinci konvolüsyonel katmanların kernelleri aynı GİB üzerinde yer alan önceki katmandaki kernel haritasına bağlanır. Tamamen bağlı katmandaki nöronlar önceki katmandaki bütün nöronlara bağlanır. Normalizasyon katmanları birinci ve ikinci konvolüsyonel katmanları takip eder. Maksimum havuzlama katmanları 5. Katmanda olduğu gibi normalizasyon katmanlarını takip eder. Her konvolüsyonel ve tamamen bağlı katmanın çıktısına RELU uygulanır. İlk konvolüsyonel katman  $224 \times 224 \times 3$  girdi görüntüsünü 4 piksellik bir stride ile  $11 \times 11 \times 3$  boyutlu bir filtre uygular. İkinci evrişimli katman, birinci evrişimli katmanın çıktısını girdi olarak alır ve  $5 \times 5 \times 48$  boyutunda 256 çekirdekle filtreler. Üçüncü, dördüncü ve beşinci evrişimli katmanlar, araya giren herhangi bir havuzlama veya normalleştirme katmanları olmadan birbirine bağlanır. Üçüncü evrişimli katman, ikinci evrişimli katmanın çıktılarına bağlı  $3 \times 3 \times 256$  boyutunda 384 çekirdeğe sahiptir. Dördüncü evrişimli katman,  $3 \times 3 \times 192$  boyutunda 384 çekirdeğe ve beşinci evrişimli katman,  $3 \times 3 \times 192$  boyutunda 256 çekirdeğe sahiptir. Tam bağlantılı katmanların her biri 4096 nörona sahiptir [76]. AlexNet mimarisi Şekil 3.13'de gösterilmiştir.



Şekil 3.13 AlexNet Mimarisinin Gösterimi [76]

AlexNet, beyin MRG'leri ve göğüs röntgenleri için en sık kullanılan modeldir. AlexNet, MRG'leri analiz eden çalışmalar arasında en yaygın yaklaşımlardan biridir [81].

### 2.9.3. GoogLeNet

GoogLeNet ismi ILSVRC14 yarışmasında doğmuştur. GoogLeNet'i, Inception mimarisinin belirli enkarnasyonuna atıfta bulunmak için de kullanılmıştır. Kalitesi biraz daha düşük olan daha derin ve daha geniş bir Inception ağı kullanılmıştır, fakat bunu gruba eklemek sonuçları marjinal bir şekilde iyileştirmiştir. Inception mimarisi, evrişimli bir görüntü ağında optimal bir yerel seyrek yapının nasıl yaklaştırılabileceğini ve kolayca elde edilebileceğini bulmaya dayanmaktadır. Bu mimarinin temel yararlı yönlerinden biri, hesaplama karmaşıklığında kontrolsüz bir şekilde hata olmadan her aşamada birim sayısını önemli ölçüde artırmaya izin vermesidir [82]. GoogLeNet, evrişimli sinir ağının önceden eğitilmiş bir sürümüdür. GoogLeNet veri kümesi, derin ağların üst düzey özellikleri ve sınıflandırıcıları entegre ettiği 22 katmandan oluşur. GoogLeNet, gerçek zamanlı olarak çalıştırmada yüksek doğruluk sağlar. Görüntüyü ızgaralara böler [83]. Inception modüllerinin içindekiler de dahil olmak üzere tüm evrişimler, düzeltilmiş doğrusal aktivasyonu kullanır. Ağdaki alıcı alanın boyutu, ortalama çıkarma ile RGB renk kanallarını alarak  $224 \times 224$ 'tür [82]. GoogLeNet katmanları, conv1, conv2, conv3, inception3a, inception3b, inception4a, inception4b, inception4c, inception4d, inception4e, inception4e, inception5a ve inception5b'den oluşmaktadır [84].

### 2.9.4. Microsoft ResNet

Daha derin sinir ağlarının eğitilmesi zordur. Eğitimi kolaylaştırmak için artık bir öğrenme çerçevesi sunulmaktadır. Artık ağların optimize edilmesi ve önemli ölçüde artırılmış derinlikten doğruluk elde edilmesi daha kolaydır [85]. 18, 50, 152 veya hatta stokastik derinliğe sahip 1202 katmana kadar çıkmaktadır [7]. ResNet için ağ mimarisi çeşitli düz/artık ağlar ile test edildi. ImageNet için iki model tanımlandı. İlki düz ağ, diğer artık ağdır. Düz ağ temeli VGG ağından esinlenerek yapılmıştır. Evrişimli katmanlar çoğunlukla  $3 \times 3$  filtrelerle sahiptir ve iki tasarım kuralına sahiptir. İlki, aynı

çıktı özelliği harita boyutu için, katmanlar aynı sayıda filtreye sahiptir. İkincisi, özellik haritası boyutu yarıya indirilirse, katman başına zaman karmaşıklığını korumak için filtre sayısı ikiye katlanır. 2 adımlı evrişimli katmanlarla doğrudan alt örnekleme gerçekleştirilir. Ağ, küresel ortalama bir havuz oluşturma katmanı ve 1000 yollu softmax ile tam bağlantılı katman sonlanır. Ağ katmanlarının toplam sayısı 34'tür. Artık ağ temeli düz ağ temeli mimarisi ile aynıdır. Her bir 3x3 filtre çiftine bir kısayol bağlantısının eklenir [85].

### 2.9.5. VGG

VGG'de çok küçük ( $3 \times 3$ ) evrişim filtrelerine sahip bir mimari kullanarak derinliği artan ağların kapsamlı bir değerlendirmesi yapılmaktadır. VGG'de önceki evrişim filtrelerine ait konfigürasyonlar derinliği 16-19 ağırlıklı katmanlarına itilerek önemli bir iyileştirme elde edilmiştir. Evrişimli ağlar (ConvNet), yakın zamanda ImageNet gibi büyük genel görüntü havuzları ve GİB'ler gibi yüksek performanslı bilgi işlem sistemleri nedeniyle mümkün hale gelen büyük ölçekli görüntü ve video tanımda büyük bir başarı elde etmiştir. VGG'de ConvNet mimarisinin başka bir önemli yönünü olan tasarım derinliği ele alınmıştır. Mimarinin diğer parametrelerini sabitletmiş ve tüm katmanlarda çok küçük ( $3 \times 3$ ) evrişim filtrelerinin kullanılması nedeniyle mümkün olan daha fazla evrişimli katman ekleyerek ağın derinliği artırılır [86]. VGG, basit evrişimli işlemleri yığılarak derin bir mimari oluşturup performansı artırdı [87]. Eğitim sırasında, ConvNet'lerimizin girdisi sabit boyutlu  $224 \times 224$  KYM görüntüdür. VGG'de yapılan tek ön işleme, eğitim setinde hesaplanan ortalama KYM değerini her pikselden çıkarmaktır. Görüntü, çok küçük bir alıcı alana sahip filtreler kullanılan bir evrişimli (dönüşüm) katman yığınından geçirilir:  $3 \times 3$  (sol / sağ, yukarı / aşağı, merkez kavramını yakalamak için en küçük boyuttur) Konfigürasyonlarında, giriş kanallarının doğrusal bir dönüşümü olarak görülebilen (ardından doğrusal olmama)  $1 \times 1$  evrişim filtreleri de kullanılır. Evrişim adımı 1 piksele sabitlenmiştir; dönş. uzaysal dolgu katman girişi, uzamsal çözünürlüğün evrişimden sonra korunacağı şekildedir, yani dolgu  $3 \times 3$  dönüşüm için 1 pikseldir. Mekansal havuzlama, maksimum beş havuzlama katmanı tarafından gerçekleştirilir. Maksimum havuz, adım 2 ile  $2 \times 2$  piksellik bir pencere üzerinde gerçekleştirilir [86].

## 2.9.6. DenseNet

DenseNet, her katmanı diğer bir katmana ileri beslemeli bir şekilde bağlayan evrişimli bir ağıdır [88]. 40 , 100, 121, 169 katmanlıdır [7]. Evrişimli ağlar, girişe yakın ve çıktıya yakın katmanlar arasında daha kısa bağlantılar içeriyorsa, eğitim için önemli ölçüde daha derin, daha doğru ve verimli olabilir. L katmanlı klasik evrişimsel ağlar L bağlantıya sahip iken DenseNet’de  $L(L+1)/2$  doğrudan katman vardır. Her katman için, önceki tüm katmanların özellik haritaları girdi olarak kullanılır ve kendi özellik haritaları girdi olarak bütün alt katmanlar içinde kullanılır. DenseNet'in birkaç önemli avantajı vardır: kaybolan gradyan problemini hafifletir, özellik yayılmasını güçlendirir, özelliğin yeniden kullanımını teşvik eder ve parametre sayısını önemli ölçüde azaltır. DenseNet mimarisi, ağa eklenen bilgiler ile korunan bilgiler arasında açık bir şekilde ayırım yapar. DenseNet katmanları çok dardır (ör. Katman başına 12 filtre). Ağın "kolektif bilgisine" yalnızca küçük bir özellik haritası seti ekler ve kalan özellik haritalarını değiştirmeden tutar. Ağdaki tüm özellik haritalarına dayalı bir karar verir [88]. Yoğun Bağlantılı Evrişimli Ağlar (DenseNet), yoğun bloklar kullanarak katmanlar arasında yoğun bağlantıları kullanan bir ESA türü önererek ResNet üzerinde geliştirildi. Bu ağlarda, her katman, girdilerinin son katmanın çıktısı veya son katmanın çıktısı artı kısa bir bağlantı olduğu geleneksel katmanlar yerine önceki tüm katmanlardan ek girdiler alır [89].

DenseNet omurgası ile Mask R-CNN kullanılarak otomatik yol hasarı tespiti çalışmasında da bir mimari geliştirilmiştir. Bu yaklaşım, görüntü özelliğini etkili bir şekilde çıkarmak için Mask R-CNN'nin omurgası olarak yoğun şekilde bağlanmış evrişim ağlarını, birden çok ölçek özelliğini birleştirmek için bir özellik piramidi ağını, yol hasarı bölgesini oluşturmak için bir bölge teklif ağını ve tamamen evrişimli bir sinir ağını yol hasarı bölgesini sınıflandırmak ve bölge sınırlama kutusunu iyileştirmek için kullanır [90]. Yol hasar tespiti ve sınıflandırması, bir nesne tespit ve sınıflandırma problemi olarak nitelendirilebilir. Mevut derin evrişimsel sinir ağları metotları ile değerlendirildiğinde Mask R-CNN nesne tespit ve sınıflandırmada başarılıdır. Chen ve arkadaşlarının yaptığı bu çalışmada Mask R-CNN çatısı kullanılmıştır [91]. Geleneksel Mask R-CNN çerçevesi, bir görüntü özellikleri çıkarma ağı, bir bölge teklif ağı ve üç dal içerir. Üç dal, nesne maskeleyme, nesne sınırlama kutusu iyileştirmesi ve

nesne sınıflandırmasıdır. Geleneksel Mask R-ESA çerçevesinde, ResNet 50/101, yol hasarı tespiti için bir görüntü özelliği çıkarma ağı olarak kullanılmıştır [90].

Chen ve arkadaşlarının önerdiği Mask R-CNN çerçevesinde, DenseNet, yol görüntüsü özellik çıkarımının omurgası olarak kullanılmıştır, ardından farklı seviyelerde özellik haritaları elde edilmiştir. Hasar görüntüsünün farklı ölçek özelliklerini birleştirmek için, özellik piramidi ağı, çok ölçekli özellik haritaları oluşturmak için kullanılmıştır. Bölge önerisi ağı kullanılmıştır, görüntü özelliği haritalarını girdi olarak almıştır ve bir dizi dikdörtgen nesne bölgesi önerisi çıkarmıştır. Her bölge teklifine bir yol hasar skoru eşlik etmiştir. Puan, teklif bölgesindeki yol hasarının olasılığı olmuştur. Özellik haritalarında bazı pencereler kaydırılabilmiştir, bu pencerelerin farklı ölçekleri ve şekilleri olmuştur (genişlik ve yükseklik oranı). Her pencere çapa olarak adlandırılmıştır ve her bir çapanın özellikleri bölge teklif ağına girilmiştir. Bölge teklif ağı, çapanın ön plan (yol hasarı) veya arka plan olma olasılığını hesaplamıştır. Pencere kutusunun regresyon parametreleri de hesaplanabilmiştir. Kutunun çapasını ve regresyon parametrelerini kullanarak bölge önerisi çapasının konumunu ve şeklini hesaplayabilmiştir. Bu bağlantı kutularında, ön planda hasar olasılığı en yüksek olan bölge önerisi seçilmiştir. Ardından, fazlalık ve yinelenen bağlantıları kaldırmak için MOB (maksimum olmayan bastırma) algoritmasını kullanılmıştır [91]. MOB'un özü, yerel maksimum teklifleri aramış ve maksimum olmayan teklifleri bastırmıştır. İlk olarak, yerel bölgede yol hasarı olasılığı en yüksek olan teklifi bulmuştur ve en yüksek puana sahip teklif ile diğer yerel teklifler arasındaki Birlik Üzerinden Kesişimi (IoU) hesaplamıştır. IoU eşikten yüksekse, teklif maksimum olmayan bir teklif olmuştur ve kaldırılmıştır [90]. Bölge teklif ağını kullanarak bölge tekliflerini aldıktan sonra, her bölge teklifinin ROI (İlgi Bölgesi) özelliğini elde etmek için ROI Align'ı kullanmıştır. ROI Align, niceleme işlemini iptal etmiş ve koordinatların kayan nokta numaraları olduğu konumda görüntü özelliği değerini elde etmek için çift doğrusal enterpolasyon yöntemini kullanmış, böylece tüm özellik toplama sürecini sürekli bir işleme dönüştürmüştür. Kayan nokta sayı kutusunun sınırını nicelemeden koruyarak her bölge önerisini yinelemiştir. Aday bölge  $k \times k$  birimlere bölünmüştür. Her birimde sabit dört koordinat konumunu, bu dört konumun değerlerini çift doğrusal enterpolasyon yoluyla hesaplanmıştır ve ardından maksimum havuzlama işlemini gerçekleştirilmiştir [91]. Mask R-CNN çerçevesinin sonunda üç ağ kafası oluşmuştur.



Birinci kafa, tamamen bağlantılı katmanı kullanan her bölge önerisi için yol hasar sınıflandırmıştır. Bu kafanın sonucu, hangi tür yol hasarının ait olduğu olasılığı göstermiştir. İkinci kafa, aynı zamanda tamamen bağlantılı katmanı kullanan sınırlayıcı kutu regresyonu olmuştur. Bu başlığın sonucu, hasarlı bölgenin doğru konumunu ve sınırlayıcı kutunun şeklini elde etmek için kullanılmıştır. Üçüncü başlık, tamamen evrişimli bir ağ aracılığıyla yol hasarı nesnesinin maskesini elde etmek için kullanılmıştır, yani bu pikseller bölge öneri kutusundaki yol hasarına ait olmuştur [90].

Önerilen Mask R-CNN çerçevesinde, DenseNet bir omurga ağı olarak kullanılan belirli avantajlara sahip olmuştur. Etkili bir şekilde görüntü özelliği çıkarma haritalarını elde edebilmiş ve ardından bunu bölgesel teklif ağı ve üç ana ağ ile paylaşabilmiştir. DenseNet, sıralı ağ adı verilen çapraz bağlantılı bir evrişimli sinir ağı modeli olmuştur. DenseNet, bir veya daha fazla yoğun şekilde bağlı modül içeren evrişimli bir sinir ağı oluşturmuştur. Yoğun şekilde bağlanmış modül, herhangi iki bitişik olmayan katman arasında iç çapraz katman bağlantılarına izin veren bir dizi işlemle seri olarak bağlanan çok sayıda evrişimli katmandan oluşmuştur. Her katmanın girdisi, önceki tüm katmanların çıktı özelliği haritasını içermiştir ve her katmanın çıktı özelliği haritaları, sonraki katmanların girdi özellikleri olarak kullanılmıştır [88]. Bu yapının avantajı, özellik yayılımını artırabilmesi ve özelliğin yeniden kullanımını teşvik edebilmiştir. Önerilen Mask R-CNN'de omurga olarak kullanılan DenseNet mimarisi yoğun şekilde bağlanmış dört blok içermiştir. Evrişimli katmanların sayısı, 101 katman da içerebilen ResNet101 ile benzemiştir. Görüntüyü girdikten sonra, ilk katman  $7 \times 7$  evrişimli bir katman ve adım 2'ye eşit  $3 \times 3$  maksimum havuzlamıştır. Daha sonra, birinci yoğun bağlı modül altı tane  $1 \times 1$  evrişimli katman ve altı tane  $3 \times 3$  evrişimli katmandan oluşmuştur. Bundan sonra ilk geçiş katmanı olmuştur. Yoğun bir şekilde bağlanan ikinci modül, on iki tane  $1 \times 1$  evrişimli katman ve on iki tane  $3 \times 3$  evrişimli katmandan oluşmuştur. Ardından ikinci geçiş katmanı gelmiştir. Üçüncü yoğun şekilde bağlanmış modül, yirmi dört tane  $1 \times 1$  evrişimli katman ve yirmi dört tane  $3 \times 3$  evrişimli katmandan oluşmuştur. Ardından üçüncü geçiş katmanı gelmiştir. Dördüncü yoğun şekilde bağlanmış modül, altı adet  $1 \times 1$  evrişimli katman ve altı adet  $3 \times 3$  evrişimli katmandan oluşmuştur. DenseNet'in son katmanı bir tane  $3 \times 3$  evrişimli katman ve ardından görüntü özellik haritaları oluşturulmuştur. [91].

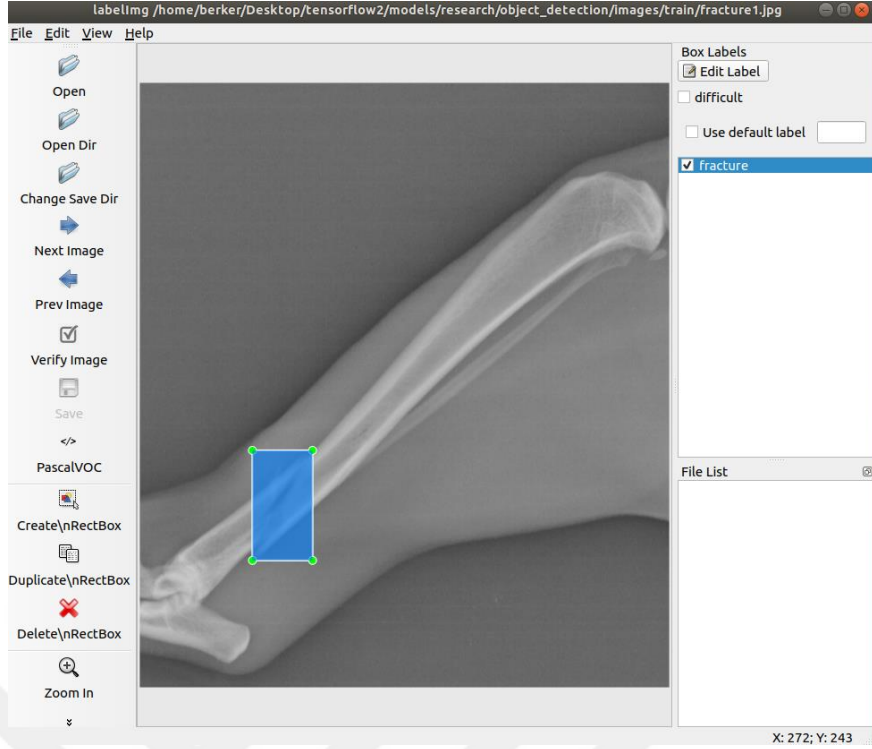
### 3. MATERYAL VE YÖNTEM

#### 3.1. Veri Seti

Bu çalışmada kullanılan veri seti bu çalışmaya özgü olarak geliştirilmiştir. Sağlam ve kırık tibia görüntüleri veteriner fakülteleri ve Ankara Büyükşehir Belediyesinden toplanmıştır. Bu görüntüleri almak için Ankara, Kırıkkale ve Selçuk Üniversiteleri Veteriner Fakülteleri Cerrahi Anabilim Dalı ile iletişime geçilmiştir. Ayrıca görüntülerin çoğu Ankara Büyükşehir Belediyesi Sincan Geçici Hayvan Bakım Ev Rehabilitasyon Merkezi'nden temin edilmiştir. Binlerce resim arasından toplam 1488 köpek ve kedi tam / kısmi vücut resmi seçilmiştir. Bu 1488 görüntü 988 köpek ve 500 kediden oluşmaktadır [20]. Bu görüntüler Tıpta Dijital Görüntüleme ve İletişim (DICOM) formatında elde edilmektedir. Köpek ve kedi tibia kemiğinin anatomik yapıları neredeyse benzerdir [92]. Bu nedenle kedi ve köpek tibia kırığı tespiti açısından aralarında bir fark yoktur. 1488 tibia görüntüsü veteriner tarafından etiketlenmiştir. Bu işlemler sırasında LabelImg [93] etiketleme aracı kullanılmıştır. LabelImg, görüntüyü sınırlayıcı kutuyla etiketlemek için kullanılan bir grafiksel görüntü etiket aracıdır. Tibia görüntülerine labelImg kullanarak açıklama eklemek için 1488 DICOM görüntüsü JPEG formatına dönüştürülmüştür.

#### 3.2. Tibia Kırıklarının Etiketleme İşlemi

Toplanan binlerce kemik görüntüsünden gerekli inceleme işlemleri yapılarak 1488 adet kedi ve köpek tibia kırık görüntüsü elde edilmiştir. 1488 görüntünün tamamında uzman veteriner hekim tarafından kırıklar tespit edilip etiketlenmiştir. Etiketleme işlemi için “labelImg” etiketleme aracı kullanılmıştır. Etiketleme aracından alınan görüntü **Hata! Başvuru kaynağı bulunamadı.**’de verilmiştir.



Şekil 3.14 Etiketleme Aracı

Etiketleme işleminin ardından uygulama etiketlenmiş olan kırık bölgesinin koordinatlarını xml dosyasına çıkarır. **Hata! Başvuru kaynağı bulunamadı.**'de xml dosyasının içeriği verilmiştir.

```

fracture1.xml
~/Desktop/tensorflow2/models/research/object_detection/images/train
Save

<annotation>
  <folder>train</folder>
  <filename>fracture1.jpg</filename>
  <path>/home/berker/Desktop/tensorflow2/models/research/object_detection/images/train/
fracture1.jpg</path>
  <source>
    <database>Unknown</database>
  </source>
  <size>
    <width>564</width>
    <height>643</height>
    <depth>1</depth>
  </size>
  <segmented>0</segmented>
  <object>
    <name>fracture</name>
    <pose>Unspecified</pose>
    <truncated>0</truncated>
    <difficult>0</difficult>
    <bndbox>
      <xmin>120</xmin>
      <ymin>391</ymin>
      <xmax>184</xmax>
      <ymax>508</ymax>
    </bndbox>
  </object>
</annotation>

```

Şekil 3.15 Etiketlenmiş Kırık Görüntüsünün Koordinat Bilgisi

### **3.3. Tibia Kemik Kırıkları Tespiti İçin Kullanılan Derin Öğrenme Yöntemleri**

Keras, yapay sinir ağları, yapay zeka ve derin öğrenme teknolojileri tasarımıdır [94]. Tüm/Kısmi vücut görüntüsünden kırık tibia kemiğinin tespiti, otomatik bulunan kırık tibia kemiğinin üzerindeki kırığın tespiti, tüm/kısmi vücut görüntüsünden tibia kemiği üzerindeki kırığın tespiti için Keras tabanlı Mask R-CNN Derin Öğrenme algoritması kullanılmıştır.

Tensorflow Nesne Tanımlama API'si açık kaynak kodlu Tensorflow üzerine inşa edilmiş bir uygulama programlama arayüzüdür. API yardımı ile kolaylıkla nesne tanıma modelleri inşa edilebilir, eğitilebilir ve çalıştırılabilir [95]. Mask R-CNN ile tüm/kısmi vücut görüntüsünden kırık Tibia kemiğinin tespit edilmesi sonucu Tibia üzerindeki kırığın tespit için Tensorflow Nesne Tanımlama API tabanlı SSD Derin Öğrenme algoritmasına verilir. Böyle bir sistem ile tibia kırığının tespiti yapılır

### **3.4. Mask R-CNN**

Mask R-CNN, bir görüntüdeki nesnelere maskeleyerek tespit etmeyi sağlayan bir metottür. Mask R-CNN, Faster R-CNN'in var olan sınırlayıcı kutu belirleyicisine paralel olarak maske nesnesinin eklenmiş halidir. Öncelikli olarak Mask R-CNN Derin Öğrenme algoritmasını kullanmak için Mask R-CNN kütüphanesi kurulması gerekmektedir. Daha sonra nesne tespiti için veri setini hazırlamak gerekmektedir. Bunun için labelImg etiketleme aracı ile etiketlenen görüntülerin xml dosyaları annots klasörü altına koyulur. Görüntüler ise images klasörü altına konulur. Xml dosyasının içerisinde kırığın bulunduğu ya da kırık Tibia kemiğinin etiketlenen kısımlarının koordinat bilgileri tutulmaktadır. Bu koordinat bilgileri parse metodu ile elde edilir. Koordinat bilgilerinde xmin, ymin, xmax, ymax bilgileri yer almaktadır. Ayrıca, genişlik ve yükseklik bilgileri de xml dosyasından çıkartılır. Veri setini yüklemek için load\_dataset metodu kullanılır [96].

Mask R-CNN modeli MS COCO nesne tespiti veri seti üzerinde uyumludur. Tibia görüntü üzerindeki kırığın ve kırık Tibia kemiğinin tespiti için bu görüntüleri ön eğitilmiş Mask R-CNN modelinde eğitilmesi gerekmektedir. Bunun için ağırlık bilgilerini içeren Mask\_RCNN\_COCO.h5 modeli indirilir. Tibia kemiği üzerindeki kırığı ve kırık Tibia kemiği için konfigürasyon sınıfı oluşturulur. Bu bölümde eğitimin kaç epoch süreceği belirtilir. Load\_weights metodu ile ön tanımlı model yüklenmiş olur. Böylece eğitime hazır hale getirilir. Eğitim sonunda Tibia kemiği üzerinde kırığı ve kırık Tibia kemiğini elde etmek için ayrı modeller oluşturulur. Test verisi ile oluşan yeni modeller test edilir [96].

### **3.5. Single Shot Detector (SSD)**

Tensorflow Nesne Tanımlama API'si ile eğitime başlamadan önce gerekli olan konfigürasyon adımlarının gerçekleştirilmesi gerekmektedir. Aşağıdaki konfigürasyon ayarlamaları yapıldıktan sonra eğitime başlanır. Eğitim sonunda Tibia kemiği üzerinde kırığı ve kırık Tibia kemiğini elde etmek için yeni bir model oluşur. Test verisi ile oluşan yeni model test edilir [95].

#### **3.5.1. Modelin API İçerisine Yerleştirilmesi**

Tibia kemik kırıklarını eğitebilmek için Tensorflow Nesne Tanımlama API'si içerisinde SSD\_Mobilenet\_v2\_quatized\_300x300\_coco\_2019\_01\_03 ön eğitilmiş model kullanılmıştır. Tensorflow Nesne Tanımlama API'si içinde yerleştirilmesi gereken dizin “models/research/object\_detection” altındadır [95].

##### **3.5.1.1. Etiketleme Sonucu Oluşan Xml Dosyalarının Tensorflow'un**

###### **Kabul Edeceği Formata Dönüştürülmesi**

Etiketlenmiş verilerin test ve eğitim olarak ayrıldıktan sonra Tensorflow'un kabul edeceği formata getirebilmek için xml dosyaları csv'ye dönüştürülmüştür. Bunun için aşağıdaki komut çalıştırılmıştır.

- python3 xml\_to\_csv.py

Daha sonra csv'yi Tensorflow'un formatı olan tfrecord' a dönüştürülmüştür. Eğiteceğimiz nesnelere bu sınıf içerisinde tanımlıyoruz. Bu dönüşüm işlemi için aşağıdaki komutlar çalıştırılmıştır [95].

- `python3 generate_tfrecord.py --csv_input=images/train_labels.csv --image_dir=images/train --output_path=images/train.record`

```
python3 generate_tfrecord.py --csv_input=images/test_labels.csv --image_dir=images/test --output_path=images/test.record
```

### 3.5.1.2. Labelmap Oluşturma ve Config Dosyalarının Düzenlenmesi

Labelmap, her nesnenin ne olduğunu, sınıf adlarının sınıf ID numaralarıyla eşleştirilmesini ifade eder. Labelmap.pbtxt dosyasını `models/research/object_detection/training` altına yerleştiriyoruz.

- ```
item {  
  id: 1  
  name: 'fracture'  
}
```

Kullandığımız ön eğitilmiş modelin config dosyası üzerinde deneme yanılma yöntemiyle kendi problemimize uygun değişiklikler yapıp modelimizin başarımı artırmaya çalışılmıştır. Buna göre config dosyasında aşağıdaki parametreler değiştirilmiştir.

Image resizer olarak `fixed_shape_resizer` kullanılmıştır. Fotoğraf boyutunu başarılı bir şekilde vererek modelin resmin boyutlarına odaklanması sağlanmıştır.

- ```
image_resizer {  
  fixed_shape_resizer {  
    height: 300  
    width: 300  
  }  
}
```

Başka önemli bir faktör ise optimizasyon yöntemidir. Sıklıkla kullanılan “rms\_prop\_optimizer”ı kullanılmıştır. Batch size 16 olarak ayarlanmıştır. Öğrenme oranı ise 0.01 olarak verilmiştir [95].

### 3.5.2. Geliştirilen Modelin Değerlendirme Kriterleri

Tibia Kemik Kırıklarının Tespitine İlişkin Sistemin Precision ve Recall değerlerini bulabilmek için IoU (Intersection of Union) değerinin hesaplanması gerekmektedir. IoU, görüntü üzerinde kesin referans ile sınırlayıcı kutu arasında kesişen kısmı ifade etmektedir [97]. **Hata! Başvuru kaynağı bulunamadı.**'te IoU hesaplama formülü verilmiştir.

IoU hesaplaması için öncelikle kesin referans (ground thruth) ile sınırlayıcı kutunun (bounding box) koordinat bilgileri üstünden aşağıdaki hesaplamaların yapılması gerekmektedir.

$$\bullet \quad x_{min\_inter} = \max(x_{min}, x_{min\_pred}) \quad (3.1)$$

$$y_{min\_inter} = \max(y_{min}, y_{min\_pred}) \quad (3.2)$$

$$x_{max\_inter} = \min(x_{max}, x_{max\_pred}) \quad (3.3)$$

$$y_{max\_inter} = \min(y_{max}, y_{max\_pred}) \quad (3.4)$$

(xmin,ymin,xmax,ymax) -> ground thruth koordinat bilgileri

(xmin\_pred,ymin\_pred,xmax\_pred,ymax\_pred) -> bounding box bilgileri

Kesişim dikdörtgenlerinin koordinatlarının minimum ve maksimumunun belirlenmesi için  $x_{min\_inter}$ ,  $y_{min\_inter}$ ,  $x_{max\_inter}$ ,  $y_{max\_inter}$  değerlerinin hesaplanması formül 3.1, 3.2, 3.3 ve 3.4'e göre yapılması gerekmektedir.

$$\bullet \quad inter\_area = \max(0, x_{max\_inter} - x_{min\_inter} + 1) * \max(0, y_{max\_inter} - y_{min\_inter} + 1) \quad (3.5)$$

Kesişim dikdörtgeninin alanının belirlenmesi için  $inter\_area$ 'nın hesaplanması formül 3.5'e göre yapılması gerekmektedir.

- $actual\_area = (df.xmax - df.xmin + 1) * (df.ymax - df.ymin + 1)$  (3.6)  
 $pred\_area = (df.xmax\_pred - df.xmin\_pred + 1) * (df.ymax\_pred - df.ymin\_pred + 1)$  (3.7)

Asıl ve Tahmin Edilen Kutuların Alanının belirlenmesi için  $actual\_area$  (formül 3.6) ve  $pred\_area$  (formül 3.7)'nin hesaplanması gerekmektedir.

- Son olarak IoU hesabını yapmak için aşağıdaki formül 3.8 kullanılır:

$$IoU = \frac{inter\_area}{float(actual\_area + pred\_area - inter\_area)} \quad (3.8)$$

Görüntü üzerinde sistemin bulduğu sonuç ile etiklediğimiz görüntünün gerçek değerleri karşılaştırıldığında True Positive mi yoksa False Positive mi olduğu sonucunu IoU üzerinden karar verilmektedir. Bu kapsamda IoU için bir eşik değer belirlenmektedir. Derin Öğrenme ile Tibia Kemik Kırıklarının tespiti için IoU eşik değeri 0,4 alınmıştır. Eğer ki IoU değeri kullanılan test görüntüsünde 0,4 üzerinde çıkarsa True Positive altında çıkarsa False Positive olarak kabul edilmiştir. IoU'ya ait eşik değer tüm test verilerinin ground truth ile sistemin bulduğu sınırlayıcı kutucuğu arasında kalan kısmın kırığı ne kadar doğru şekilde kapsadığını gözlemleyerek belirlenmiştir. Kırık Tibia kemiğinin IoU eşik değeri de aynı yöntemle belirlenmiştir. Sistemin görüntü üzerinde Tibia kırığı olarak tespit etme olasılığını veren Confidence score (Güven Skoru)'un eşik değerini ise tüm test verilerinde kırığın doğru olarak tespit edilmesi skoruna bakılarak eşik değeri  $\geq \%90$  olarak belirlenmiştir. Kırık Tibia kemiğinin Confidence score'una ait eşik değeri de aynı yöntemle belirlenmiştir.

DP (Gerçek Pozitif): Uzman hekim tarafından etiketlenen kırık ile sistemin Tibia kırığı olarak tespit ettiği bölge örtüşüyorsa “Doğru Pozitif” olarak adlandırılır.

YP (Yanlış Pozitif): Uzman hekim tarafından etiketlenen kırık ile sistemin Tibia kırığı olarak tespit ettiği bölge örtüşmüyorsa “Yanlış Pozitif” olarak adlandırılır.



YN (Yanlış Negatif): Uzman hekim tarafından Tibia kırığı etiketlenmiş fakat sistem Tibia kırığı olarak görüntü üzerinde hiçbir şey tespit edememişse “Yanlış Negatif” olarak adlandırılır.

DN (Doğru Negatif): Sisteme sağlam Tibia kemiği verilmiş ve sistem bu duruma sağlam Tibia kemiği olarak tanımlamışsa “Doğru Negatif” olarak adlandırılır.

Bir görüntüde birden fazla DP ve YP değerleri olabilir. Örneğin, confidence değeri en yüksek olan DP çıktığını varsayalım. İkinci en yüksek confidence değerinde YP çıktığını varsayalım. Bu durumda en yüksek değer DP olduğu için ve Tibia kırığını doğru şekilde tespit ettiği için sadece DP olan değer sistemin performansını ölçmek için kullanılmıştır. Bu sebepten YP değeri sistemin performansı hesaplamak için kullanılmamıştır.

Başka bir örnek ise confidence değeri en yüksek olan YP çıktığını varsayalım. İkinci en yüksek confidence değerinde DP çıktığını varsayalım. Bu durumda hem YP hem de DP değeri sistemin performansını ölçmek için değerlendirmeye alınmıştır. Burada DP değerinin alınmasının sebebi Tibia kırığını ikinci en yüksek olasılıkla doğru şekilde tespit etmiş olmasıdır.

Bu işlemin ardından Precision (Kesinlik) (formül 3.9) ve Recall (Hassasiyet) (formül 3.10) değerleri hesaplanmaktadır.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3.9)$$

$$\text{Geri Alma} = \frac{DP}{DP+YN} \quad (3.10)$$

Sistemin doğruluğunu tespit etmek için “Accuracy (Doğruluk)” formül 3.11 ile hesaplanır. Doğruluk, Doğru Pozitif ve Doğru Negatif olan durumların tüm durumlara oranıdır [98].

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.11)$$

Tibia kırığını doğru şekilde tespit edebilme yeteneğini bulmak için “Sensitivity (Hassasiyet)” formül 3.12 ile hesaplanır. Sensitivity, True Positive durumların Tibia kırıklı tüm durumlara oranıdır [98].

$$\text{Hassasiyet} = \frac{DP}{DP+YN} \quad (3.12)$$

Sağlam Tibia kemiğini doğru şekilde tespit edebilme yeteneğini bulmak için “Specificity (Özgüllük)” formül 3.13 ile hesaplanır. Specificity, kırık olmayan (sağlam) Tibia kemiklerdeki negative test sonuçlarının olasılığıdır [98].

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3.13)$$

Bu veriler ışığında sistemin genel performansını tespit etmek için F-Score [99] formül 3.14 ile hesaplanması gerekmektedir.

$$F = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.14)$$

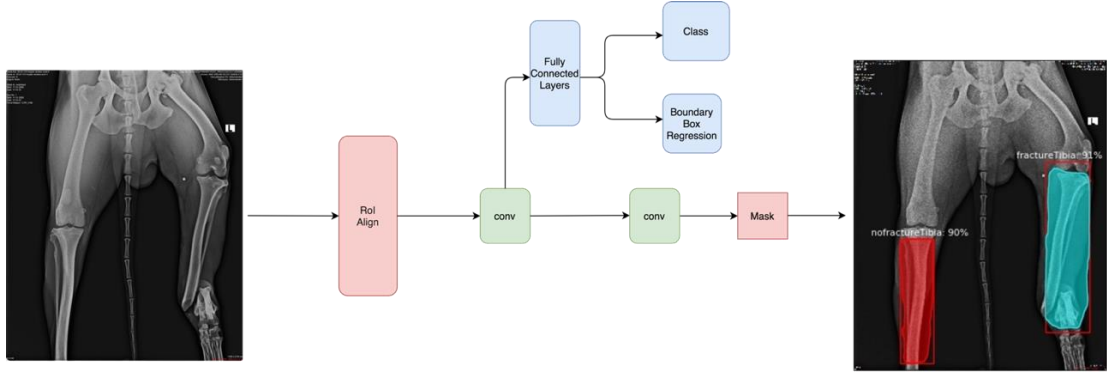
## 4. BULGULAR

### 4.1. Geliştirme Ortamı

Tibia veri seti, kırık ve sağlam tibianın sınıflandırılması, kırık tibianın tespiti ve kırık tibianın kırık yerinin belirlenmesi için Mask R-CNN kullanılarak eğitilmiştir. Veri seti iki bölümden oluşmaktadır. Birinci bölüm eğitim, ikinci bölüm ise test için kullanılmıştır. Bu veri seti ön eğitilmiş Mask R-CNN modeli ile kırık ve sağlam tibianın sınıflandırılması, kırık tibianın tespiti ve kırık tibianın kırık yerinin belirlenmesi için yeniden eğitilmiştir. Böylece, bu çalışmalar için transfer öğrenimi işlemleri gerçekleştirilmiştir. Eğitim için Mask\_RCNN\_COOC modelinin ağırlıkları kullanılmıştır. Eğitim boyunca kullanılan Mask R-CNN konfigürasyon değerleri belirlenmiştir. Batch size: 2, learning rate: 0.001, learning momentum: 0.9, weight decay: 0.0001, epoch: 4000. Farklı boyuttaki görüntüleri kullanabilmek için, Mask R-CNN'de ölçekleme oranı için görüntü yeniden boyutlandırılmıştır. Image\_min\_dim ve image\_max\_dim sırasıyla 800 ve 1024 piksel olarak kullanılmıştır. Görüntüler kısa kenarın image\_min\_dim olduğu kadar ölçeklenmiştir, ancak uzun kenar image\_max\_dim'den büyükse ölçekleme uygulanmamıştır. Bu sistemin geliştirilmesi aşamasında Keras API kullanılmıştır. Ayrıca, kırık tibia kemiği üzerindeki kırık yerinin tespiti işlemi içinde SSD derin öğrenme teknolojisi kullanılmıştır. Eğitim boyunca kullanılan SSD konfigürasyon değerleri de belirlenmiştir. Batch size: 16, learning rate: 0.01, learning momentum: 0.9, weight decay: 0.9, epoch: 4000. SSD'de farklı boyuttaki görüntüleri ölçeklendirmek için "Fixed Shape Resizer" kullanılmıştır. Uzunluk ve genişlik 300 olarak belirlenmiştir. Bu sistemin geliştirilmesi aşamasında Tensorflow API kullanılmıştır. Bu çalışmaların geliştirilmesi 30.5 GB NVIDIA Tesla M60 GPU ve Ubuntu 18.04 işletim sisteminde yapılmıştır.

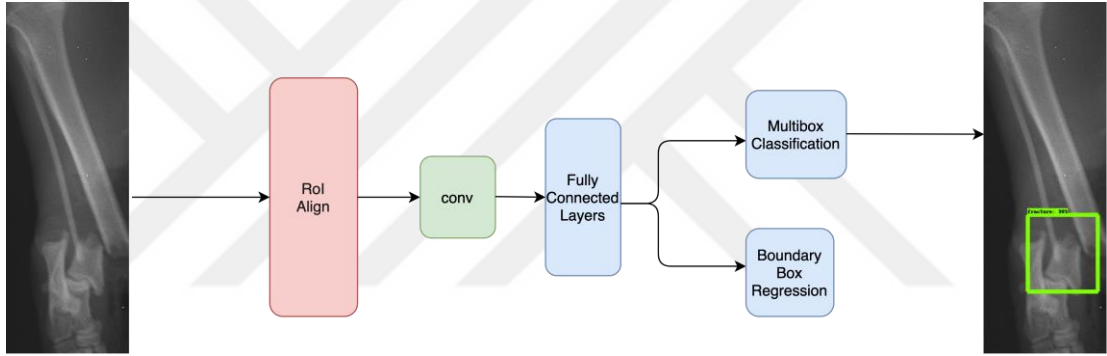
## 4.2. Tibia Kırığının Tespiti İçin Önerilen Sistem Mimarisi

Birçok gizli katman ve nörondan oluşan derin öğrenme mimarisi, standart sinir ağına göre ham veriler veya görüntü üzerinde iyi sonuçlar elde etmek için bir avantaj sağlar [100]. Mask R-CNN [94] ve SSD [101] gibi birçok derin öğrenme teknolojisi vardır. Mask R-CNN bir görüntüdeki nesnelere lokalize ve maskeleyiş işlemi yaparak nesnelere tespit etmeye sağlayan bir metottur. Mask R-CNN, Faster R-CNN'nin mevcut sınırlayıcı kutu tanımlayıcısına paralel olarak maske nesnesinin eklenmesidir. Mask R-CNN yapısında, nesnenin bölümlere ayrılmış kısmını tahmin etmek için her bir ilgi Bölgesine (ROI) maskeler uygulanır. Uygulama ve eğitim için yararlı bir çatı sağlar. Ayrıca, hızlı bir altyapı sunar. SSD, görüntüdeki nesnelere algılamak için kutu sınırlayıcıları ve güven puanları üreten ve bundan sonra son algılamayı elde etmek için kutu sınırlayıcılarına maksimum olmayan bastırma uygulayan bir derin öğrenme teknolojisidir [101]. Kırık ve sağlam tibia'yı sınıflandırmak ve tespit etmek ve kırık tibia'nın kırık yerinin belirlenmesi için 4 (Ç1, Ç2, Ç3 ve Ç4) farklı çalışma gerçekleştirilmiştir. Ç1, tam / kısmi vücut dijital görüntüsünden sistem tarafından otomatik olarak elde edilen tibia kırık lokasyonunun Mask R-CNN kullanılarak tespit edilmesi ve lokalize edilmesi ile ilgilidir [20]. Ç1, iki fazdan ( Faz 1 ve Faz 2) oluşmaktadır. İlk fazda Mask R-CNN kullanarak sağlam ve kırık tibia'ların tespit edilmesi ve sınıflandırması işlemi gerçekleştirilmiştir. Kırık tibia görüntüsü tüm / kısmi vücut dijital görüntüsünden sistem tarafından otomatik olarak ayrıştırıldıktan sonra, ikinci aşamada kırık tibiada Mask R-CNN kullanılarak kırık yeri tespit ve lokalize edilmiştir. Ç2, Mask R-CNN kullanılarak tüm / kısmi vücut dijital görüntüsünden doğrudan kırık tibianın kırık yerini tespit etmek ve lokalize etmekle ilgilidir [20]. Ç1 ve Ç2'de Mask R-CNN mimarisi kullanılmıştır (Şekil 4.1).



Şekil 4.1 Mask R-CNN Mimarisi

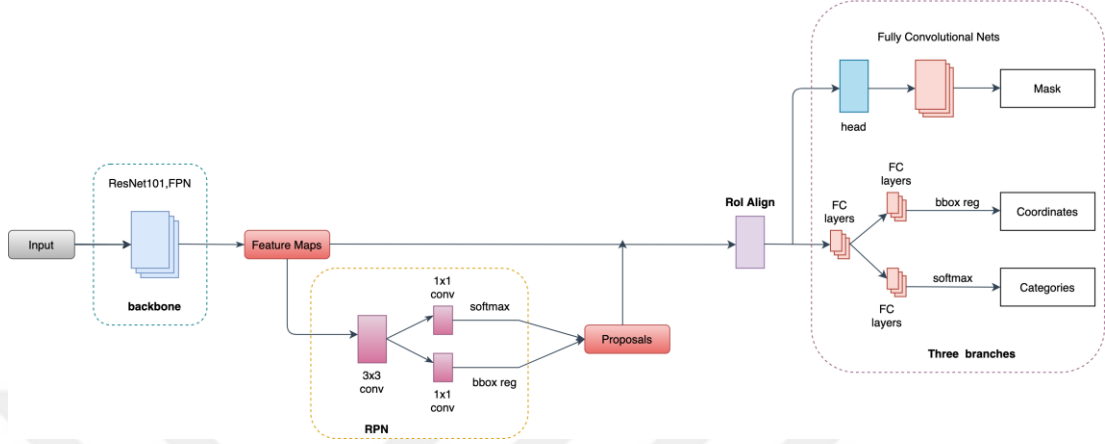
Ç3'te Ç1-Faz 1'den elde edilen kırık tibia'nın kırık yerini lokalize etmek için Ç1-Faz 2'de kullanılan Mask R-CNN yerine SSD derin öğrenme teknolojisi kullanılmıştır [20]. SSD mimari Şekil 4.2'de gösterilmiştir.



Şekil 4.2 SSD Mimarisi

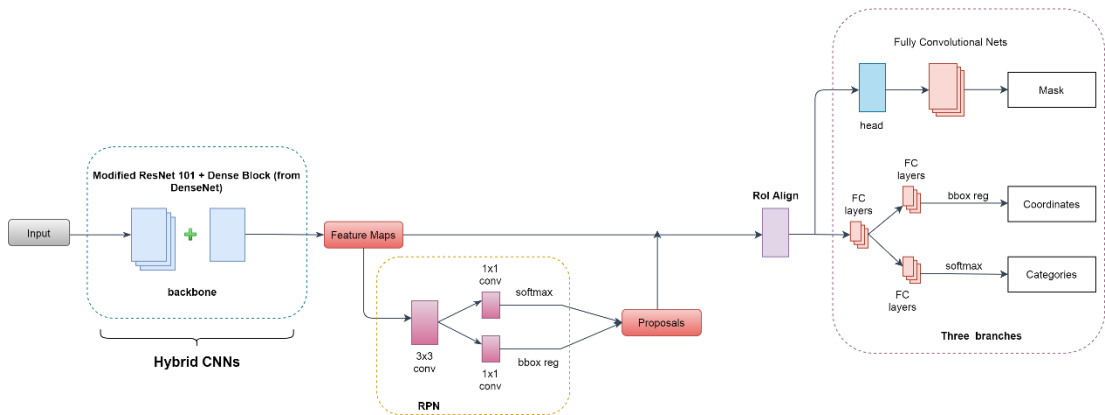
Ç4'te Ç1-Faz 2'de Mask R-CNN çatısında görüntüden özellik çıkarımı için kullanılan klasik ResNet CNN omurgası yerine hibrit bir model geliştirilmiştir [102]. Backbone, Mask R-CNN framework'ü için bel kemiği olarak nitelendirebiliriz. Çünkü özellik çıkarımı işlemi omurga bölümünde yapılmaktadır ve sonuçların iyi ya da kötü çıkması bu bölümün eğitim aşamasındaki öğrenmesine çok büyük katkı sağlamaktadır. Bu sebepten daha başarılı performans elde edebilmek için omurga bölümünde hibrit bir çalışma yapmanın daha etkin olacağını düşünülmüştür. Şekil 4.3'te görüldüğü üzere orijinal Mask R-CNN framework'ündeki backbone kısmında önemli ESA modellerinden olan ResNet modeli kullanılmıştır. ResNet, atlama bağlantıları kullanır ve doğrusal olmayan dönüşümleri atlamak için kimlik işlevlerini kullanır. Bu nedenle gradyan kimlik işlevi aracılığıyla doğrudan arka katmanlardan ön katmanlara akabilir.

Bununla birlikte, birçok parametre içerir, aşdaki akış bilgisini engelleyebilir ve kaybolan gradyan problemine sahip olabilir. Bu da bilgi akışını yavaşlatarak uzun süren eğitimlerden dolayı performansı düşürebilmektedir [75].



Şekil 4.3 Orijinal Mask R-CNN mimarisinin Katman Seviyesinde Görünüşü [Esinlenildi;75]

ResNet'in özellik çıkarım yönünden çok başarılı sonuçlar verdiği [94] görüldüğünden, ResNet'i tamamen çıkarıp tek başına başka bir ESA modeli kullanmak yerine, ResNet'de ağda yavaşlığa sebep olabilecek bölüm yerine daha dar ağ katmanı içeren ve DenseNet'de de [75] kullanılan "dense blok" ile "ResNet"'i hibrit yapı haline getirmenin (Şekil 4.4'te görüldüğü üzere) daha yararlı bir model olacağını düşünülmüştür.




Şekil 4.4 Omurgası Hibritlendirilmiş Mask R-CNN Mimarısının Katman Seviyesinde Görüntüsü

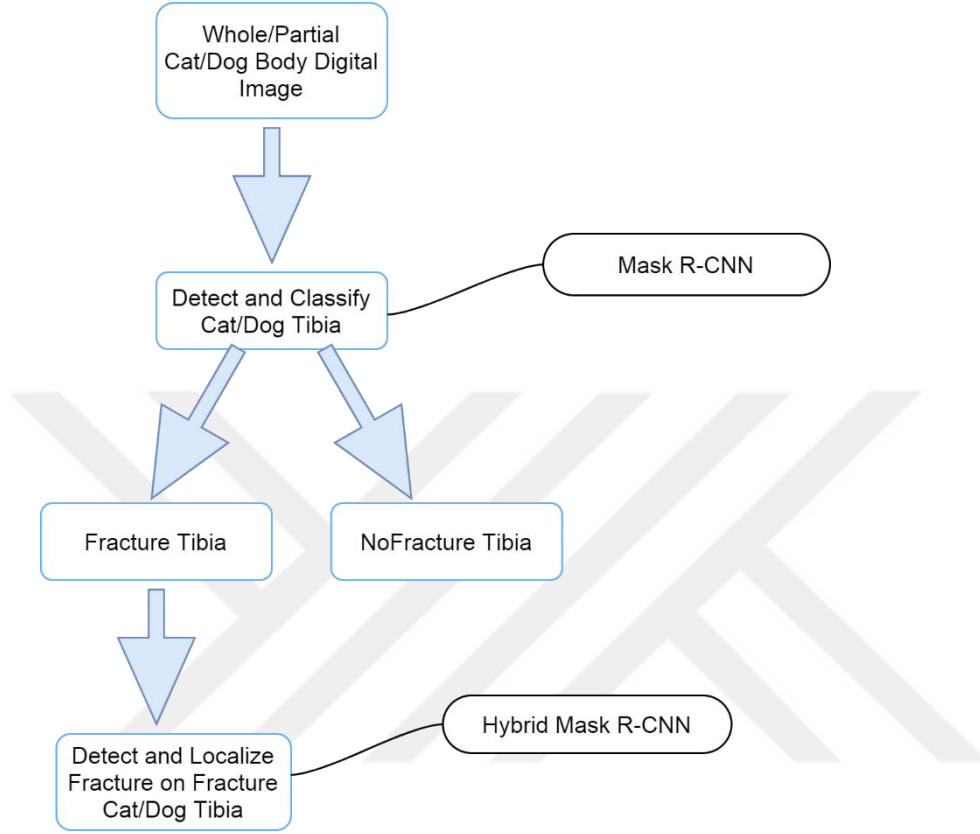
ResNet mimarisi 5 fazdan oluşmaktadır (Çizelge 5.1). ResNet mimarisinin 4. Fazının 23 bloklü convolution yapısından dolayı ağırlığa sebep olabileceği düşünülerek bir blok eksiltip 22 bloğa düşürülerek modifiye edilmiştir (Çizelge 5.1 **Hata! Başvuru kaynağı bulunamadı.** ve Şekil 4.4). 5. Fazında ise 3 blok convolution içeren ağdan bir blok eksiltip yerine DenseNet’de de kullanılan bir tane dense blok eklenerek ağdaki bilgi akışı hızlandırılarak modelin öğrenme performansı artırma hedeflenmiştir.

Çizelge 5.1 ResNet 101 [75] ile Modified ResNet 101 + Dense Block (from DenseNet)’un Mimari Karşılaştırması

<b>Katmanlar</b>	<b>ResNet101</b>	<b>Modifiye ResNet 101 + Dense Block</b>
Convolution	7 x 7 conversion, Stride 2	7 x 7 conversion, Stride 2
Pooling	3 x 3 max pool, Stride 2	3 x 3 max pool, Stride 2
Conv2_X	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 3$	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 3$
Conv3_X	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 4$	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 4$
Conv4_X	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 23$	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 22$ (Modifiye ResNet 101)
Conv5_X	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 3$	$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 1x1 \text{ conv} \end{bmatrix} \times 2$
Dense Block		$\begin{bmatrix} 1x1 \text{ conv} \\ 3x3 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 1$
Convolution Layer	3 x 3 conv	


**Hibrit CNN**

Yapılan bu çalışmalara göre Ç4, tibia kırığının tespiti için önerilen sistem mimarisidir. Önerilen çatinın akış şeması Şekil 4.5Şekil 4.4'te verilmiştir.



Şekil 4.5 Önerilen Sistem Mimarisinin Akış Şeması

Çalışmanın bütün adım fazlarında önerilen sistem tam otomatik olarak çalışmaktadır. Önerilen sistemde herhangi bir manuel işlem uygulanmamıştır.

### 4.3. Performans Değerlendirmesi

Kırık ve sağlam tibianın tespiti ve sınıflandırma ve kırık tibianın kırık yerinin lokalize etme performansını değerlendirebilmek için bazı metrikler hesaplanmıştır. Sistemin performansını değerlendirmek için Intersection of Union (IoU) gerekli metriklerden birisidir. IoU, kesin referans ile görüntüdeki sınırlayıcı kutu arasında kesişen kısımdır [97]. Kesin referans ve sınırlayıcı kutu karşılaştırıldığında, sonucun Doğru Pozitif mi yoksa Yanlış Pozitif mi olduğuna IoU üzerinden karar verilmiştir. Bu bağlamda, IoU




için eşik değeri belirlendi. IoU, Ç1,Ç2, Ç3 ve Ç4 için 0.4 olarak alınmıştır. Örneğin, IoU 0.4'ten büyükse, sonuç Doğru Pozitifdir. Değilse Yanlış Pozitifdir. IoU için eşik, tüm test verilerinin kesin referans ile sistem tarafından bulunan sınırlayıcı kutu arasındaki tibia kırığını ne kadar doğru bir şekilde kapsadığını gözlemleyerek belirlenmiştir. Sağlam ve kırık tibia'nın tespiti ve bütün ya da kısmi vücut görüntüsünden kırık yerinin tespiti için IoU eşik değeri aynı yöntemle belirlenmiştir. Güven puanı, kırık tibia da kırık tespit etme ya da tibia'nın kırık mı sağlam mı olduğunun sınıflandırmasının olasılığıdır. Eğer etiketlenmiş kırık bölgesi ile sistem tarafından tespit edilmiş kırık bölgesi ile örtüşüyorsa Doğru Pozitif olarak tanımlanmıştır. Eğer örtüşmüyorsa Yanlış Pozitif olarak tanımlanmıştır. Eğer sistem görüntü üzerinde herhangi bir şey tespit edemiyor fakat görüntü üzerinde kırık varsa bu durum Yanlış Negatif olarak tanımlanmıştır. Eğer görüntü üzerinde herhangi bir kırık yoksa ve sistem de görüntü üzerinde kırık tespit etmemişse bu durum Doğru Negatif olarak tanımlanmıştır.

Yapılan bu 4 çalışmada kırık tibia görüntüsü üzerinde birden fazla Doğru Pozitif ve Yanlış Pozitif elde edildiği durumlar olmuştur. Bir örnekte en yüksek güven puanı Doğru Pozitif iken ikinci en yüksek güven puanı Yanlış Pozitifdir. Bu bağlamda en yüksek değer Doğru Pozitif olduğundan ve tibia kırığını doğru şekilde tespit ettiğinden sistemin performansını ölçerken yalnızca Doğru Pozitif değerler kullanılmıştır. Diğer bir örnekte en yüksek güven skoru Yanlış Pozitif iken ikinci en yüksek güven puanı Doğru Pozitifdir. Bu durumda sistem performansını hesaplarken hem Doğru Pozitif hem de Yanlış Pozitif kullanılmıştır. Doğru Pozitif değerinin burada alınmasının nedeni tibia kırığının ikinci en yüksek olasılıkla doğru saptanmasıdır. Doğruluk [96], sistemin ne kadar doğrulukla tibia kırığını tespit ettiğini hesaplayan metriktir. Doğruluk, Doğru Pozitif ve Doğru Negatif durumlarının tüm durumlara oranıdır. Elde edilen bu metrikler ışığında bütün sistemin performansını elde etmek için F-Score [103] metriği kullanılmıştır.

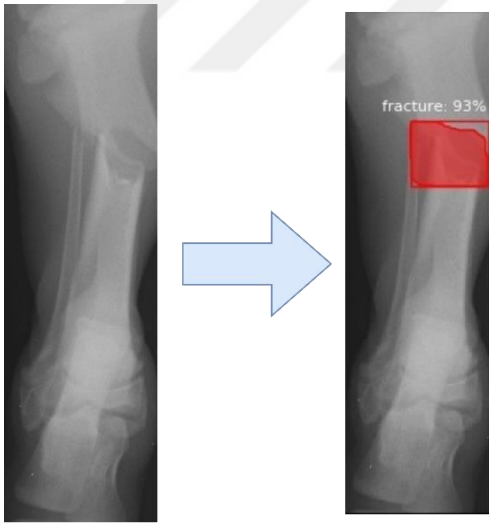
Ç1'in birinci fazında 1488 sağlam ve kırık tibia veri seti kullanılmıştır. Toplam veri seti eğitim için 595 sağlam ve 595 kırık, test için 149 sağlam ve 149 kırık tibia görüntüsü ayrılmıştır. Köpek veri seti eğitim için 286 sağlam ve 514 kırık, test için 76 sağlam ve 112 kırık tibia görüntüsü ayrılmıştır. Kedi veri seti eğitim için 309 sağlam

ve 81 kırık, test için 73 sağlam ve 37 kırık tibia görüntüsü ayrılmıştır. Bütün/kısmi vücut görüntüsünden sağlam ve kırık tibiaları tespit ve sınıflandırmak için Mask R-CNN kullanılmıştır. IoU oranı 0.4'den büyük değerler olarak ayarlanmıştır. Toplam veri seti üzerinde modelin doğruluk ve F1 skoru sırasıyla 74% ve %85 olarak elde edilmiştir. 149 görüntünün yalnızca 7 tanesinde kırık tibia'nın sınıflandırması ile ilişkili olarak bir tahminde bulunamamıştır. 149 görüntünün yalnızca 2 tanesinde sağlam tibia'nın sınıflandırmasıyla ilgili olarak bir tahminde bulunamamıştır. Köpek veri seti üzerindeki modelin doğruluk ve F1 skoru sırasıyla 72.4% ve 84% olarak elde edilmiştir. 112 görüntünün yalnızca 2 tanesinde kırık tibia'nın sınıflandırması ile ilişkili olarak bir tahminde bulunamamıştır. 76 görüntünün yalnızca 1 tanesinde sağlam tibia'nın sınıflandırmasıyla ilgili olarak bir tahminde bulunamamıştır. Kedi veri seti üzerindeki modelin doğruluk ve F1 skoru sırasıyla 76.6% ve 86.7% olarak elde edilmiştir. 37 görüntünün yalnızca 1 tanesinde kırık tibia'nın sınıflandırmasıyla ilgili olarak bir tahminde bulunamamıştır. 73 görüntünün yalnızca 1 tanesinde sağlam tibia'nın sınıflandırmasıyla ilgili olarak bir tahminde bulunamamıştır. Böylece, 518 kırık tibia (441 köpek ve 77 kedi) görüntüleri 744 kırık tibia (626 köpek ve 118 kedi kırık tibia) görüntüsünden otomatik olarak sistem tarafından tespit edilmiştir. 744 kırık tibia görüntüsü eğitim ve test veri setlerinden oluşturulmuştur. Bütün/kısmi vücut görüntüsünden sınırlayıcı kutu koordinatları tarafından otomatik olarak çıkartılarak eğitim ve test sonuçlarından 518 kırık tibia görüntüsü elde edilmiştir. Bütün vücut görüntüsünden tespit edilmiş ve sınıflandırılmış sağlam ve kırık tibia görüntüleri Şekil 4.6'da verilmiştir.



Şekil 4.6 Bütün Vücut Görüntüsünden Tespit Edilmiş ve Sınıflandırılmış Sağlam ve Kırık Tibia Görüntüsü

Sağlam ve kırık tibia'nın bulunduğu toplam 298 test verisi 433.1 saniye içinde tespit edilip sınıflandırılmıştır. Bir görüntü için ortalama 1.45 saniye sürmüştür. 188 köpek test verisinde sağlam ve kırık tibia'yı tespit edip sınıflandırması 272.6 saniye sürmüştür. 110 kedi test verisinde sağlam ve kırık tibia'yı tespit edip sınıflandırması 159.5 saniye sürmüştür. Ç1'in ikinci fazında 518 kırık tibia, 415 eğitim (360 köpek ve 55 kedi) ve 103 test (81 köpek ve 22 kedi) olarak ayrılmıştır. IoU değeri 0.4'den büyük olarak belirlenmiştir. Toplam veri seti üzerinde modelin F1 skoru 84.5%'tür. Kırık tibia üzerindeki kırığın tespitinde 103 (köpek ve kedi) görüntüden yalnızca 8'ide tahminde bulunamamıştır. Köpek veri seti üzerinde modelin F1 skoru 87.1%'dir. Kırık tibia üzerindeki kırığın tespitinde 81 köpek görüntüsünden yalnızca 6'sında tahminde bulunamamıştır. Kedi veri seti üzerinde modelin F1 skoru 74.3%'tür. Kırık tibia üzerindeki kırığın tespitinde 22 kedi görüntüsünden yalnızca 2'sinde tahminde bulunamamıştır. Sistem tarafından otomatik olarak bütün/kısmi vücut görüntüsünden elde edilen kırık tibia üzerindeki kırık yerinin Mask R-CNN ile tespiti ve belirlenmesi Şekil 4.7'de verilmiştir.




Şekil 4.7 Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Tibia Üzerindeki Kırık Yerinin Mask R-CNN ile Tespiti ve Belirlenmesi

103 toplam test verisinde kırık tibia'nın kırık yeri 375.3 saniye içerisinde tespit ve lokalize edilmiştir. Bir görüntü için ortalama 3.6 saniye sürmüştür. 81 köpek test verisinde kırık tibia'nın kırık yeri 291.6 saniye içinde tespit ve lokalize edilmiştir. 22

kedi test verisinde kırık tibia'nın kırık yeri 79.2 saniye içinde tespit ve lokalize edilmiştir. Tüm döngü 2 fazdan oluşmaktadır. İlk fazda Mask R-CNN kullanarak sağlam ve kırık tibia tespit edilerek sınıflandırıldı. İkinci fazda sistem tarafından otomatik olarak bütün/kısmi vücut görüntüsünden elde edilen kırık tibia üzerindeki kırık yerinin Mask R-CNN ile tespiti yapılmıştır. Sistem tarafından otomatik olarak kırık tibia üzerindeki kırık tespitinin tüm döngüsü bir görüntü için ortalama 5.05 saniye sürmüştür.

Ç2'de toplam 744 kırık tibia veri seti 595 eğitim ve 149 test verisi olarak ayrılmıştır. Ayrıca, 149 test verisi sağlam tibia olarak kullanılmıştır. Köpek veri setinde 514 eğitim ve 112'si test verisi olarak ayrılmıştır. 76 köpek test verisi de sağlam tibia olarak kullanılmıştır. Kedi veri setinde 81 eğitim ve 37'si test verisi olarak kullanılmıştır. 73 kedi test verisi de sağlam tibia olarak kullanılmıştır. IoU oranı 0.4'ten büyük olarak belirlenmiştir. Toplam veri seti üzerinden modelin doğruluğu ve F1 skoru sırasıyla 52.1% ve 68.5% olarak elde edilmiştir. 149 görüntünün yalnızca 35'inde bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Köpek veri seti üzerinden modelin doğruluğu ve F1 skoru sırasıyla 51.7% ve 68.1% olarak elde edilmiştir. 112 görüntünün yalnızca 28'sinde bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Kedi veri seti üzerinden modelin doğruluğu ve F1 skoru sırasıyla 53% ve 69.3% olarak elde edilmiştir. 37 görüntünün yalnızca 7'sinde bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Mask R-CNN kullanarak bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerinin tespiti ve belirlenmesi Şekil 4.8'da gösterilmiştir.




Şekil 4.8 Mask R-CNN Kullanarak Bütün/Kısmi Vücut Görüntüsünden Doğrudan Kırık Tibianın Kırık Yerinin Tespiti ve Belirlenmesi

2991.8 saniye içinde 149 toplam test verisinde bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerinin tespiti ve belirlenmesi işlemi yapılmıştır. Bir görüntü için ortalama 20 saniye sürmüştür. 2520 saniye içinde 112 köpek test verisinde bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerinin tespiti ve belirleme işlemi yapılmıştır. 460 saniye içinde 37 kedi test verisinde bütün/kısmi vücut görüntüsünden doğrudan kırık tibianın kırık yerinin tespiti ve belirlenmesi işlemi yapılmıştır.

Ç3'te S1'in 2.fazında Mask R-CNN yerine kullanılan SSD derin öğrenme algoritması, sistem tarafından otomatik olarak bütün/kısmi vücut görüntüsünden elde edilen kırık tibia üzerindeki kırık yerinin tespiti için kullanılmıştır. IoU oranı 0.4'ten büyük olarak belirlendi. Toplam veri seti üzerinde modelin F1 skoru 46.2%'dir. 103 görüntünün yalnızca 36'sında kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Köpek veri seti üzerinde modelin F1 skoru 48.1%'dir. 81 görüntünün yalnızca 26'sında kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Kedi veri seti üzerinde modelin F1 skoru 42.9%'dir. 22 görüntünün yalnızca 10'unda kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Sistem tarafından otomatik

olarak bütün/kısmi vücut görüntüsünden elde edilen kırık tibia üzerindeki kırık yerinin SSD ile tespiti ve belirlenmesi Şekil 4.9'da gösterilmiştir.




Şekil 4.9 Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Tibia Üzerindeki Kırık Yerinin SSD ile Tespiti ve Belirlenmesi


103 toplam test verisinde kırık tibiyanın kırık yerini tespit ve lokalize edilmesi 7.8 saniye içerisinde gerçekleşmiştir. Bir görüntü için ortalama 0.075 saniye sürmüştür. 81 köpek test verisinde kırık tibiyanın kırık yerini tespit ve lokalize edilmesi 6.15 saniye içerisinde gerçekleşmiştir. 22 kedi test verisinde kırık tibiyanın kırık yerini tespit ve lokalize edilmesi 1.575 saniye içerisinde gerçekleşmiştir.

Ç4'te Ç1'in 2.fazında klasik Mask R-CNN omurgası yerine hibridize edilmiş Mask R-CNN omurgası kullanarak bütün/kısmi vücut görüntüsünden elde edilen kırık tibia üzerindeki kırık yerinin tespiti yapılmıştır. IoU oranı 0.4'ten büyük olarak belirlendi. Toplam veri seti üzerinde modelin F1 skoru 85.8%'dir. 103 görüntünün yalnızca 18'nde kırık tibiyanın kırık yerini tespiti için bir tahmin yapamamıştır. Köpek veri seti üzerinde modelin F1 skoru 87.8%'dir. 81 görüntünün yalnızca 12'sinde kırık tibiyanın

kırık yerini tespiti için bir tahmin yapamamıştır. Kedi veri seti üzerinde modelin F1 skoru 77.7%'dir. 22 görüntünün yalnızca 6'sında kırık tibianın kırık yerini tespiti için bir tahmin yapamamıştır. Sistem tarafından otomatik olarak bütün/kısmi vücut görüntüsünden elde edilen kırık tibia üzerindeki kırık yerinin omurgası hibridize edilmiş Mask R-CNN ile tespiti ve belirlenmesi Şekil 4.10 ve Şekil 4.11'de gösterilmiştir.



Şekil 4.10 Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Kedi Tibia'sı Üzerindeki Kırık Yerinin Omurgası Hibridize ile Tespiti ve Belirlenmesi



Şekil 4.11 Sistem Tarafından Otomatik Olarak Bütün/Kısmi Vücut Görüntüsünden Elde Edilen Kırık Köpek Tibia'sı Üzerindeki Kırık Yerinin Omurgası Hibridize ile Tespiti ve Belirlenmesi

103 toplam test verisinde kırık tibianın kırık yerini tespit ve lokalize edilmesi 296.64 saniye içerisinde gerçekleşmiştir. Bir görüntü için ortalama 2.88 saniye sürmüştür. 81 köpek test verisinde kırık tibianın kırık yerini tespit ve lokalize edilmesi 233.28 saniye içerisinde gerçekleşmiştir. 22 kedi test verisinde kırık tibianın kırık yerini tespit ve lokalize edilmesi 63.36 saniye içerisinde gerçekleşmiştir. Bu çalışmalara ait metrikler Çizelge 5.2, Çizelge 5.3 ve Çizelge 5.4'te belirtilmiştir.



Çizelge 5.2 Mask R-CNN Kullanarak Tibiadaki Kırıkların Tespit, Sınıflandırma ve Belirleme Çalışmalarının Metrik Sonuçları

Çalışma (Ç)	Mask R-CNN																				
	Köpek							Kedi							Toplam						
	P (%)	R (%)	A (%)	Se (%)	Sp (%)	F1 (%)	ART (sn)	P (%)	R (%)	A (%)	Se (%)	Sp (%)	F1 (%)	OCS (sn)	P (%)	R (%)	A (%)	Se (%)	Sp (%)	F1 (%)	OCS (sn)
Ç1-F1	74.5	96.2	72.4	92.4	84.8	84	1.45	77.6	98.3	76.6	94.4	89.3	86.7	1.45	75.7	97	74	92.7	86.9	85	1.45
Ç1-F2	83.1	91.4	-	-	-	87.1	3.6	65	86.6	-	-	-	74.3	3.6	79.3	90.5	-	-	-	84.5	3.6
Ç2	59.6	79.5	51.7	73.2	40.7	68.1	20	57.7	86.6	53	61.9	53.4	69.3	20	59	81.7	52.1	71.3	46.9	68.5	20

P: Precision R: Recall A: Accuracy Se: Sensitivity Sp: Specificity F1: F1 Score OCS: Ortalama Cevap Süresi F: Faz

Çizelge 5.3 SSD Kullanarak Tibia Kırığı Üzerindeki Kırık Bölgesinin Tespiti ve Belirlenmesinin Metrik Sonuçları

Çalışma (Ç)	SSD											
	Köpek				Kedi				Toplam			
	P (%)	R (%)	F1 (%)	OCS (sec)	P (%)	R (%)	F1 (%)	OCS (sec)	P (%)	R (%)	F1 (%)	OCS (sec)
Ç3	46.4	50	48.1	0.075	50	37.5	42.9	0.075	46.2	46.2	46.2	0.075

P: Precision R: Recall F1: F1 Score OCS: Ortalama Cevap Süresi.

Çizelge 5.4 Omurgası Hibridize Edilmiş Mask R-CNN Kullanarak Tibia Kırığı Üzerindeki Kırık Bölgesinin Tespiti ve Belirlenmesinin Metrik Sonuçları

Çalışma (Ç)	Omurgası Hibridize Edilmiş Mask R-CNN											
	Köpek				Kedi				Toplam			
	P (%)	R (%)	F1 (%)	OCS (sn)	P (%)	R (%)	F1 (%)	OCS (sn)	P (%)	R (%)	F1 (%)	OCS (sn)
Ç4	91.5	84.4	87.8	2.88	87.5	70	77.7	2.88	90.8	81.4	85.8	2.88

P: Precision R: Recall F1: F1 Score OCS: Ortalama Cevap Süresi

## 5. TARTIŞMA

Dünya Sağlık Örgütü'nün (WHO) 2018 verilerine göre, küresel ölçekte insan ölümlerinin yaklaşık %34'ü tıbbi verilerin yanlış yorumlanmasından kaynaklandığını gösteriyor. Bu nedenle, klinik tanının tüm aşamalarının iyileştirilmesi önemlidir [104]. Özellikle derin öğrenme alanındaki son gelişmeler, görüntülerin daha iyi algılanmasını ve karmaşık verilerin makineler tarafından daha iyi yorumlanmasını sağlamıştır [105,106]. Evrişimli sinir ağı (ESA), derin öğrenmede en yaygın olarak görüntüleri ve video işlemeyi analiz etmek için kullanılan bir derin sinir ağı sınıfıdır [107]. Tek başına kullanılmanın dezavantajlarını en aza indirmek ve her birinin yararlı yönlerini birleştirmek için birçok hibrit makine öğrenimi yöntemi geliştirilmiştir [108]. Uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS), karbondioksitin difüzyon katsayısını tahmin etmek için beş farklı evrimsel algoritma ile birleştirilmiştir. ANFIS-PSO'nun hibrit makine öğrenimi modeli diğer modellerden daha iyi performans gösterir (R2: 0.9978) [109]. Elektroensefalografi (EEG) tabanlı beyin bilgisayar arayüzü (BCI) uygulamalarında gerçek zamanlı olarak oküler artefaktların (OA) ortadan kaldırılması için yeni bir bağımsız bileşen analizi (ICA) ve uyarlanmış gürültü iptali (ANC) kombinasyonuna dayanan hibrit bir yaklaşım geliştirildi. OA'nın giderilmesi ve altta yatan EEG'nin geri kazanılması açısından hibrid yöntemin performansının diğer karşılaştırılan yöntemlerden daha iyi olduğu gözlemlenmiştir [110]. Akciğer hastalığının teşhisi için VGG Data STN'yi ESA (VDSNet) ile birleştiren yeni bir hibrit yöntem geliştirilmiştir. VDSNet, diğer yöntemlerden (vanilya grisi,% 67,8; vanilya RGB,% 69; hibrit ESA,% 69,5; VGG,% 63,8) [110] göre daha yüksek bir doğrulama doğruluğu (% 73) sergilemiştir. Klinisyenler için önemli olan EEG'lerin otomatik analizi ile birlikte beyin izleme. Bununla birlikte, klinisyenler yöntemin duyarlılık ve özgüllüğünün klinik kabul için sırasıyla %95 ve %5'in altında olması gerektiğini belirtmişlerdir [111]. Golmohammadi ve arkadaşları [111], gizli Markov modellerine ve derin öğrenmeye dayanan hibrit yapının klinik olarak kabul edilebilir performans seviyelerine yaklaşabileceğini belirtmişlerdir. Tıbbın farklı alanlarında hibrit uygulamalar yapılmış olsa da kırık teşhisinde hem tıpta hem de veteriner hekimliğinde kırık tespiti konusunda geliştirilmiş bir uygulama bulunmadığından bu araştırmada yapay zeka alanında hibrit bir yöntem geliştirilmesi amaçlanmıştır.

Kırık teşhisinde otomatik kırık tespit sistemi önemli bir konudur. İnsan kırıklarında bir çok çalışma gerçekleştirilmiştir. Bununla birlikte derin öğrenme metotları kullanarak otomatik kırık tespitine ilişkin hayvanlarda bir çalışma yoktur. Kedi ve köpekler üzerine ilk otomatik kırık tespit akıllı sistemidir [20]. Şuanki araştırmada ön işlem ve veri artırımı metotları uygulanmamıştır. Test sonuçlarına göre önerilen çatı olan ve hibrit yapı içeren Ç4'ün tibia kırık tespit performansı (85.8%), Ç1 (84.5%), Ç2 (68.5%) ve Ç3'ün (46.2%) kırık tespit performansından daha yüksektir. Ayrıca, önerilen çatının cevap süresi (2.88 saniye), Ç1 (5.05 saniye) ve Ç2'nin cevap sürelerinden (20 saniye) daha hızlıdır. Ç3'ün performansı en düşük olmasına rağmen cevap süresi Ç1, Ç2 ve Ç4'den daha hızlıdır. Bütün çalışmalarda kullanılan orjinal Mask R-CNN, omurgası hibridize edilmiş (Modifiye Edilmiş ResNet 101 + DenseNet'den Elde Edilmiş Dense Blok) Mask R-CNN, ve SSD ile ayrı ayrı köpek ve kedi veri setlerinde değerlendirildiği zaman, köpeklerde tibia kırığının kırık yerinin tespit performansı kedilerdekinden daha yüksek olduğu gözlenmiştir (Çizelge 5.2, Çizelge 5.3 ve

Çizelge 5.4). Bunun sebebi toplam veri setinde kedilerin sayısı köpeklerin sayısından daha az olmasından kaynaklanıyor olabilir. Farklı bilgisayar destekli kırık tespit sistemlerini içeren insan klinik çalışmalarında farklı performans metrik değerleri mevcuttur [105]. Röntgen görüntüsü kullanılan bu araştırmaların bir tanesinde el bileği/el/ayak bileği için elde edilen doğruluk, duyarlık, özgüllük sonuçları sırasıyla 0.83, 0.9 ve 0.88'dir [112]. Proksimal humerus çalışmasında [12] kırık tespit için doğruluk, duyarlık, özgüllük sonuçları sırasıyla 0.96, 0.99 ve 0.97'dir. Bu araştırmanın Ç1 sonuçlarına göre doğruluk önceki araştırma sonuçlarına göre daha az fakat duyarlılık ve özgüllük benzerdir (Çizelge 5.2). Diğer taraftan kırık tibia üzerinde kırık yerini tespit etme performansı (F1-Skor) yapılan bu araştırmadaki hibrit çalışma ile 85.8% yüksek bir değer elde edilmiştir. Bu araştırmada doğruluğun insanlar üzerine yapılan kırık çalışmalarına göre biraz daha az olmasının sebebi bu çalışmalarda çok farklı köpek ve kedi ırklarının kullanmasından kaynaklanmış olabilir.

Bu çalışmanın diğer çalışmalara göre en önemli yönü (örn: dijital röntgen görüntüsü üzerinden proksimal humerus manuel olarak kesilip daha sonra kesilen bu kısım üzerinden kırık tespiti yapan sistemler geliştirilmiştir [12] bütün/kısmi vücut

görüntüsünden otomatik olarak kırık tibia tespit edilip sonrasında yine otomatik olarak kırık tibia üzerindeki kırık bölgesinin tespit ve lokalize etmesidir. Aynı şekilde bu çalışmada geliştirilen yeni hibrit yöntemin, manuel olarak kesilmiş 143 köpek tibia görüntüsü üzerinde SSD teknolojisi ile kırıkların tespit etme performansına (%68) göre [19] oldukça başarılı olduğu da görülmüştür.

Önerilen sistemin sonucu olarak metrikler, kedi ve köpeklerin tibia kırığı tespit etme ve lokalize etme konusunda umut vericidir. Kırık teşhisinin bu tür akıllı sistemler yardımıyla yaygınlaştırılması, hayvan sağlığı açısından hızlı ve doğru teşhis koyma için faydalı olacaktır.



## 6. SONUÇLAR VE ÖNERİLER

Bu çalışma ile hayvan sağlığı için çok önemli olan tibia'daki kırığın teşhisini kolay ve güvenilir şekilde sağlayan bir yöntem ortaya konmaya çalışılmıştır. Son yıllarda, tıbbi görüntüleme tekniklerindeki teknolojik gelişmeler tespit kalitesinde artış ve maliyetteki düşüş nedeniyle X-Ray gibi klasik tanı yöntemlerine alternatif hale gelmişlerdir. Bu sebepten bilgisayar destekli sistemler ile otomatik tespit etme yöntemleri önemli hale gelmiştir. Derin öğrenme gibi en gelişmiş bilgisayar destekli yöntemler kullanılarak insanlarda kırık teşhisi yapılmaktadır. ESA uygulaması geleneksel (klasik) X-Ray floroskopisi, MRI ve CT gibi çeşitli tıbbi görüntüleme yöntemlerinde sınıflandırma ve segmentasyon için kullanılmaktadır. ESA tekniklerinin tıbbi uygulamaları, klinisyenlerin hastalıkları daha çabuk teşhisine ve sınıflandırmasına (kanserin sınıflandırılması, kırık tanısı, nörolojik hastalıklar ve biyomedikal görüntü alma sistemleri gibi) yardımcı olur. Segmentasyon ve obje tespitine dayalı araştırmalar, son birkaç yılda ESA'ların gelişimini yakından takip etmiştir. Bu tez çalışması kapsamında köpek ve kedilerde tibia üzerindeki kırıkların daha doğru ve hızlı tespiti ve belirlenmesi için bilgisayar destekli bir sistem geliştirilmiştir. Önerilen sistem tibia üzerindeki kırık tespitini daha doğru ve hızlı bir şekilde yapabilmesi için Mask R-CNN teknolojisindeki özellik çıkarımında kullanılan ResNet modelini DenseNet'de yer alan dense blok ile birleştirerek hibritleştirilmesidir. Sistem mimarisi Ankara, Kırıkkale ve Selçuk Üniversiteleri Veteriner Fakülteleri Cerrahi Anabilim Dallarından ve Ankara Büyükşehir Belediyesi Sincan Geçici Hayvan Bakım Ev Rehabilitasyon Merkezi'nden temin edilen sağlam ve kırık tibia görüntüleri ile test edilmiştir. Sistemin ilk fazında Mask R-CNN çatısı kullanılarak sağlam ve kırık tibia'ların tespit edilmesi ve sınıflandırması işlemi gerçekleştirilmiştir. Kırık tibia görüntüsü tüm / kısmi vücut dijital görüntüsünden sistem tarafından otomatik olarak %85'lik doğruluk oranıyla ve 1.45 saniyelik kısa bir sürede ayrıştırılmıştır. Sistemin ikinci fazında kırık tibia'da hibritleştirilmiş Mask R-CNN kullanılarak kırık yeri tespit ve lokalize edilmiştir. Böylece %85.8 yüksek doğruluk oranıyla ve ortalama 2.88 saniyelik hızlı tespit süresiyle tibia kemiği üzerindeki kırıklar başarıyla lokalize edilmiştir.

Bu alıřmada elde edilen yazılım sayesinde uzman veteriner hekim klinik alıřmalarda ve kırık kemiđin tedavisi safhasında teřhis destek aısından geliřtirilen bu sistemi kullanabilecektir. Bu sistem ile beraber veteriner hekimlerin teřhis ve tedavi iin ayıracakları iř sureleri kısılacaktır. Boyelikle klinisyenler ya da hekimler daha az rontgen ekileceđinden daha az radyasyona maruz kalacaklardır. Sistem, dođru teřhise katkıda bulunacađından kedi ve kpeklerin sađlıklarına daha hızlı Őekilde kavuřmasını sađlayacaktır. İleriki sureerde, diđer hayvan trleri iin de bu sistem geliřtirilerek diđer kemikler zerindeki kırıkların otomatik tespiti iinde yaygınlařtırılabilir. Ayrıca, yeni geliřtirilecek sistem ile kemiklerin kırık tiplerine gre sınıflandırma iřlemi yapılarak veteriner hekimin teřhis suresi kısılacaktır.





## KAYNAKLAR

- [1] Ryan, S., Bacon, H., Endenburg, N., Hazel, S, Jouppi, R., Lee, N, Seksel, K, Takashima, G. WSAVA Animal welfare guidelines. JSAP. 60(5): E1-E46, 2019.
- [2] Verga, M., Michelazzi, M. “*Companion Animal Welfare And Possible Implications On The Human-Pet Relationship*”. Ital. J. Anim. Sci. 8 (Suppl. 1): 231-240, 2009.
- [3] Sađmanlıgil, V, Cengiz, F, Salgırlı, Y, Atasoy, F, Ünal N, Petek, M. Hayvan davranıřları ve refahı. Anadolu Üniversitesi Yayını. No: 2332, İkinci Baskı, Eskiřehir, 2013.
- [4] Broom DM. 2017. Animal welfare in the European Union. Study for the peti committee.[https://www.researchgate.net/profile/Donald-Broom/publication/315721435\\_Animal\\_Welfare\\_in\\_the\\_European\\_Union/links/58dea012aca272059aac6f2/Animal-Welfare-in-the-European-Union.pdf](https://www.researchgate.net/profile/Donald-Broom/publication/315721435_Animal_Welfare_in_the_European_Union/links/58dea012aca272059aac6f2/Animal-Welfare-in-the-European-Union.pdf). (Eriřim tarihi: 14.04.2021)
- [5] Endenburg, N., Tkashima, G., van Lith, H.A., Bacon, H., Hazel, S.J., Jouppi, R., Lee, N.Y.P., Seksel, K., Ryan, S. Animal welfare worldwide, the opinion of practicing veterinarians. J App Anim Welf Sci. pp. 1-23, 2020. DOI: 10.1080/10888705.2020.1717340
- [6] Sonntag, Q., Overall, K.L. Key determinants of dog and cat welfare: behaviour, breeding and household lifestyle. Rev. Sci. Tech. OIE, 33 (1): 213-220, 2014.
- [7] Ting, D.S.W., Peng, L., Varadarajan, A.V., Keane, P.A., Burlina, P.M., Chiang, M.F., Schmettere, L., Pasquale, L.R., Bressler, N.M., Webster, D.R., Abramorff, M., Wong, T.Y. Deep learning in ophthalmology: The technical and clinical considerations. Prog Retin Eye Res. 72: 100759, 2019.
- [8] Challen R., Denny, J., Pitt, M., Gompels, L., Edwards, T., Tsaneva-Atanasova, K. Artificial intelligence, bias and clinical safety. BMJ Qual Saf. 28 (3): 231–237, 2019.

- [9] Yi, P.H., Hui, F.K., Ting, D.S.W. Artificial intelligence and radiology: collaboration is key. *J Am Coll Radiol.* 15 (5): 781-783, 2018.
- [10] Pesapane, F., Volonte, C., Codari, M., Sardanelli, F. Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States. *Insights into Imaging.* 9 (5): 745-753, 2018.
- [11] Kim, D.H., MacKinnon, T. Artificial intelligence in fracture detection: transfer learning from deep convolutional neural networks. *Clin Radiol.* 73(5): 439-445, 2018.
- [12] Chung S.W., Han S.S., Lee J.W., Oh, K-S., Kim, N.R., Yoon, J.P., Kim, J.Y., Moon, S.H., Known, J., Lee, H-J., Noh, Y-M., Kim, Y. Automated detection and classification of the proximal humerus fracture by using deep learning algorithm. *Acta Orthop.* 89 (4): 468-473, 2018.
- [13] Roth, H., Wang, Y., Yao, J., Lu, L., Burns, J., Summers, R. Deep convolutional networks for automated detection of posterior-element fractures on spine CT. *arXiv:1602.00020*, 2016.
- [14] Lindsey, R., Daluiski, A., Chopra, S., Lachapelle, A., Mozer, M., Sicular, S., Hanel, D., Gardner, M., Gupta, A., Hotchkiss, R., Potter, H. Deep neural network improves fracture detection by clinicians. *PNAS.* 115 (45): 11591-11596, 2018.
- [15] Chai, H.Y., Wee, L.K., Swee, T.T., Hussain, S. Gray-level co-occurrence matrix bone fracture detection. *WSEAS Trans Syst.* 10 (1): 7-16, 2011.
- [16] Mahendran, S.K., Santhosh Baboo, S. An enhanced tibia fracture detection tool using image processing and classification fusion techniques in X-ray images. *GJCST.* 11 (14): 23-28, 2011.

- [17] Lim, S.E., Xing, Y., Chen, Y., Leow, W.K., Howe, T.S., Png, M.A. Detection of femur and radius fractures in X-ray images. Proc 2nd Int Conf on Advances in Medical Signal and Information Processing. pp. 249-256, 2004.
- [18] Kvam, J., Gangsei, L.E., Kongsro, J., Schistad Solberg, A.H. The use of deep learning to automate the segmentation of the skeleton from CT volumes of pigs. *Transl Anim Sci.* 2 (3): 324-335, 2018.
- [19] Baydan, B., Ünver, H.M. Dataset creation and SSD mobilenet V2 performance evaluation for dog tibia fracture detection. II. International Ankara Congress of Scientific Research, Ankara, Turkey, pp. 433-443, 2020.
- [20] Baydan, B., Ünver, H.M. Detection of tibial fracture in cats and dogs with deep learning. *Ankara Univ Vet Fak Derg*, (Article in press), 2020. DOI: 10.33988/auvfd.772685
- [21] Chen, K., Pang, J., Xiong, Y., Li, X., Sun, S., Feng, W., Liu, Z., Shi, J., Ouyang, W., Loy, C.C., Lin, D. Hybrid task cascade for instance segmentation. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 15-20 June 2019, Long Beach, CA, USA, pp. 4969-4978, 2019.
- [22] Li, Xiaomeng & Chen, Hao & Qi, Xiaojuan & Dou, Qi & Fu, Chi-Wing & Heng, Pheng. (2017). H-DenseUNet: hybrid densely connected unet for liver and liver tumor segmentation from CT volumes. *IEEE Transactions on Medical Imaging*. PP. 10.1109/TMI.2018.2845918.
- [23] Kannoja, Suresh & Jaiswal, Gaurav. Ensemble of hybrid CNN-ELM model for image classification. 2018 5th International Conference on Signal Processing and Integrated Networks (SPIN), 22-23 Feb 2018, Noida, Delhi-NCR, India, pp. 538-541, 2018.

- [24] Wang, Z.J., Turko, R., Shaikh, O., Park, H., Das, N., Hohman, F.M., Kahng, M., Chau, D.H. CNN Explainer: Learning convolutional neural networks with interactive visualization. *IEEE Trans Vis Compu Graph.* 27 (2): 1396-1406, 2021.
- [25] Arandjelovic, R., Gronat, P., Torii, A., & Pajdla, T., Sivic, J. NetVLAD: CNN architecture for weakly supervised place recognition. *IEEE Trans. Pattern Anal Mach Intell.* 40 (6): 1437-1451, 2018.
- [26] Gao, S-H, Cheng, M-M., Zhao, K., Zhang, X.-Y., Ming-Hsuan, Y., Philip, T. Res2Net: A new multi-scale backbone architecture. *IEEE Trans. Pattern Anal Mach Intell.* 43 (2): 652-662, 2021.
- [27] Chen, Z., Zhang, J., Ding, R., Marculescu, D. ViP: virtual pooling for accelerating CNN-based image classification and object detection. 2020 IEEE Winter Conference on Applications of Computer Vision (WACV), 1-5 March 2020, Snowmass, CO, USA, pp. 1169-1178, 2020.
- [28] Georgiou, T., Schmitt, S., Bäck, T., Chen, W., Lew, M. 2021. Norm Loss: An efficient yet effective regularization method for deep neural networks, 25th International Conference on Pattern Recognition (ICPR 2020), 13-18 September 2020, Milano, Italy, 2020.
- [29] Li, X., Li, X., Pan, D., Zhu, D. On the learning property of logistic and softmax losses for deep neural networks. Thirty-Fourth AAAI Conference on Artificial Intelligence, 7-12 February 2020, New York, USA, pp. 4739-4746, 2020.
- [30] Abbaspour, S., Fotouhi, F., Sedaghatbaf, A., Fotouhi, H., Vahabi, M., Linden, M. A comparative analysis of hybrid deep learning models for human activity recognition. *Sensors.* 20 (19): 5707-, 2020.
- [31] Wang, H., Zhao, T., Li, L.C., Pan, H., Liu, W., Gao, H., Han, F., Wang, Y., Qi, Y., Liang, Z. A hybrid CNN feature model for pulmonary nodule malignancy risk differentiation. *J Xray Sci Technol.* 26 (2): 171-187, 2018.

- [32] Chen, M., Kalra, M.K., Yun, W., Cong, W., Yang, Q., Nguyen, T., Wei, B., Wang, G. A mixed reality approach for stereo-tomographic quantification of lung nodules. *J Xray Sci Technol.* 24(4): 615–625, 2016.
- [33] B., Srinivas, B., Rao, G.S. A Hybrid CNN-KNN model for MRI brain tumor classification. *IJRTE*, 8 (2): 5230-5235, 2019.
- [34] Monika, Chhillar, R.S. Study of K-NN evaluation for text categorization using multiple level learning. *Int J Comput Appl.* 122 (22): 9-12, 2015.
- [35] Dos Santos CAS, C. and Welfer, D. A Novel hybrid SVM-CNN method for extracting characteristics and classifying cattle branding. *LAJC.* 6 (1): 9-64, 2019.
- [36] Agarap, A. F. An architecture combining convolutional neural network (CNN) and support vector machine (SVM) for image classification. *arXiv1712.03541*, 2017.
- [37] Rani, K.S., Kumari, K.M., Amulya, G., Pothineni, E., Pavani, V., Reddy, P.S. Leg bone fracture segmentation and detection using advanced morphological techniques. *IJRTE.* 8 (23): 1246-1249, 2019.
- [38] Oryan, A., Monazzah, S., Bigham-Sadegh, A. Bone injury and fracture healing biology. *Biomed Environ Sci.* 28 (1): 57-71, 2015.
- [39] Florencio-Silva, R., Sasso, G.R.S., Cerri, E., Simoes, M.J., Cerri, P.S. Biology of bone tissue: structure, function, and factors that influence bone cells. *Biomed Res Int.* 2015 (1): 1-18, 2015.
- [40] Mahajan, T., Ganguly, S., Para, P.A. Fracture management in animals: a review. *JCBPSC.* 5 (4): 4053-4057, 2015.

- [41] Ma, Y., Luo, Y. Bone fracture detection through the two-stage system of Crack-Sensitive Convolutional Neural Network. *Inform Med Unlocked*. 22 (2021): 1-10, 2021.
- [42] Dimililer, K. IBFDS: Intelligent bone fracture detection system. 9th international conference on theory and application of soft computing, computing with words and perception, ICSCCW 2017, 22-23 August 2017, Budapest, Hungary, pp. 260-267, 2017.
- [43] Beyaz, S., Açııcı, K., Sümer, E. Femoral neck fracture detection in X-ray images using deep learning and genetic algorithm approaches. *Jt Dis Relat Surg*. 31 (2): 175-183, 2020.
- [44] Singh, R., Chandrapuria, V.P., Shahi, A., Bhargava, M.K., Swamy, M., Shukla, P.C. Fracture occurrence pattern in animals. *J Anim Res*. 5 (3): 611-616, 2015.
- [45] De luliis, G., Pulera, D. The cat. In: *The dissection of vertebrates. A laboratory Manual. Third Edition.* s179-307, Ed: by G. De luliis and D. Pulera. Elsevier, 2019. <https://www.sciencedirect.com/topics/agricultural-and-biological-sciences/tibia>, (Erişim tarihi: 16.03.2021)
- [46] Anonim. Ankara Üniversitesi Veteriner Fakültesi Anatomi Anabilim Dalı Arsivi. Dışkapı, Ankara, 2021.
- [47] Jain, R., Shukla, B.P., Nema, S., Shukla, S., Chabra, D., Karmore, S.K. Incidence of fracture in dog: A retrospective study. *Vet Pract*. 19 (1): 63-65, 2018.
- [48] Macri, F., Angileri, V., Russo, M.T., Tabbi, M., Di Pietro, S. Evaluation of bone healing using contrast-enhanced ultrasonography in non-operative treatment of tibial fracture in a puppy dog. *Animals*. 11 (2): 1-7, 2021.
- [49] Glyde, M., Arnett, R. Tibial fractures in the dog and cat: Options for management. *Ir Vet J*. 59 (5): 290-295, 2006.

- [50] Kumar, K., Mogha, I.V., Aithal, H.P., Kinjavdekar, P., Amarpal, Singh, G.R., Pawde, A.M., Kushwaha, R.B. Occurrence and pattern of long bone fractures in growing dogs with normal and osteopenic bones. *J Vet Med A*, 54 (9): 484-490, 2007.
- [51] Ben Ali, L.M. Incidence, occurrence, classification and outcome of small animal fractures: a retrospective study (2005-2010). *WASET International Journal of Animal and Veterinary Sciences*. 7 (3): 191-196, 2013.
- [52] Bashir, M., Amarpal A., Kinjavdekar, P., Aithal H.P., Pawde, A.M., Dhama, K. An update on diagnostic imaging techniques in veterinary practice. *Adv Anim Vet Sci*. 2: (4S): 64-77, 2014.
- [53] Langley-Hobbs, S. Biology and radiological assessment of fracture healing. In *Pract*. 25 (1): 26-35, 2003.
- [54] Jones, R.M., Sharma, A., Hotchkiss, R., Sperling, J.W., Hamburger, J., Ledig, C., O'Toole, R., Gardner, M., Venkatesh, S., Roberts, M.M., Sauvestre, R., Shatkhin, M., Gupta, A., Chopra, S., Kumaravel, M., Daluiski, A., Plogger, W., Nascone, J., Potter, H.G., Lindsey, R.V. Assessment of a deep-learning system for fracture detection in musculoskeletal radiographs. *NPJ Digit Med*. 30 (3):144, 2020.
- [55] Singh, G., Mishra, A., Sagar, D. An overview of artificial intelligence. *SBIT Journal of Sciences and Technology*. 2 (1): 1-4, 2013.
- [56] Das, S., Dey, A., Pal, A., Roy, N. Applications of artificial intelligence in machine learning: review and prospect. *Int J Comput Appl*. 115 (9): 31-41, 2015.
- [57] Dhankar, M., Walia, N. An introduction to artificial intelligence. In: *Emerging trends in big data, IoT and cyber security*. pp. 105-108. Ed: by M. Kumar, R. Choudhary and S.K. Pandey. Maharaja Surajmal Institute, Excellent Publishing Services, New Delhi, 2020.

- [58] Pohl, J. Artificial superintelligence: extinction or nirvana? InterSymp-2015 - 27th International Conference on Systems Research, Informatics and Cybernetics (IIAS), Baden-Baden, Germany, pp. 1-20, 2015.
- [59] Goertzel, T. The path to more general artificial intelligence. *J ExpTheor Artif Intell.* 26 (3): 1-17, 2014.
- [60] Haenlein, M., Kaplan, A. A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. *Calif Manag Rev.* 61 (4): 5-14, 2019.
- [61] Namatēvs, I. Deep convolutional neural networks: structure, feature extraction and training. *Information Technology and Management Science.* 20 (1): 40-47, 2017.
- [62] Işıklı, S. Bulanık mantık ve bulanık teknolojiler. Ankara Üniversitesi, DTCF. <http://dergiler.ankara.edu.tr/dergiler/34/923/11510.pdf>, (Erişim tarihi: 15.04.2021)
- [63] Shetty, S.K., Siddiqa, A. Deep learning algorithms and applications in computer vision. *IJCSE.* 7 (7): 195-201, 2019.
- [64] Chauhan, S.P., Bahal, P. Introduction to machine learning. In: Emerging trends in big data, IoT and cyber security. pp: 115-119. Ed: by M. Kumar, R. Choudhary and S.K. Pandey. Maharaja Surajmal Institute, Excellent Publishing Services, New Delhi, 2020.
- [65] Sutton, R.S., Barto, A.G. Reinforcement learning: An introduction. Second Ed. The MIT Press, Cambridge, <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf> , (Erişim tarihi: 15.04.2021)
- [66] Singh, A., Thakur, N., Sharma, A. A review of supervised machine learning algorithms. 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), New Delhi, India, pp. 1310-1315, 2016.



- [67] Pai, P.F., Wang, W.C. Using machine learning models and actual transaction data for predicting real estate prices. *Appl Sci.* 10 (17): 2-11, 2020.
- [68] Albawi, S., Mohammed, T.A., Al-Zawı, S. Understanding of a convolutional neural network. *ICET2017, Antalya, Turkey*, pp. 1-6, 2017.
- [69] Emmert-Streib, F., Yang, Z., Feng, H., Tripathi, S., Dehmer, M. An introductory review of deep learning for prediction models with big data. *Front Artif. Intell.* 3 (Article 4): 1-23, 2020.
- [70] Gavrishchaka, V.V., Yang, Z., Miao, R., Senyukova, O. Advantages of hybrid deep learning frameworks in applications with limited data. *Int J Mach Learn Comput.* 8 (6): 549-558, 2018.
- [71] Shrestha, A., Mahmood, A. Review of deep learning algorithms and architectures. *IEEE Access.* 7: 53040-53065, 2019.
- [72] Girshick, R. Fast R-CNN. 2015 *IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, pp. 1440-1448, 2015.
- [73] Nguyen, C.C., Tran, G.S., Nghiem, T.P., Doan, N.Q., Gratadour, D., Burie, J.C., Luong, C.M. Towards real-time smile detection based on faster region convolutional neural network. 2018 *1st International Conference on Multimedia Analysis and Pattern Recognition (MAPR)*, Ho Chi Minh, Vietnam, pp. 1-6, 2018.
- [74] Anonim. How does the region proposal network (RPN) in Faster R-CNN work? <https://www.quora.com/How-does-the-region-proposal-network-RPN-in-Faster-R-CNN-work>. (Eriřim tarihi: 01.11.2018)
- [75] Anonim. Faster R-CNN explained. <https://medium.com/@smallfishbigsea/faster-r-cnn-explained-864d4fb7e3f8> (Eriřim tarihi: 01.11.2018)

- [76] Krizhevsky, A., Sutskever, I., Hinton, G.E. ImageNet classification with deep convolutional neural networks. *Commun ACM*. 60 (6): 84-90, 2017.
- [77] İnik, Ö., Ülker, E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *GBAD*. 6 (3): 85-104, 2017.
- [78] Smith, L.N., Hand, E.M., Doster, T. Gradual DropIn of layers to train very deep neural networks. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, pp. 4763-4771, 2016.
- [79] Badea, M. S., Felea, I., Florea, L., Vertan, C. The use of deep learning in image segmentation, classification and detection. *arXiv:1605.09612*, 2016.
- [80] Lecun, Y., Bottou, L., Bengio, Y., Haffner, P. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*. 86 (11): 2278-2324, 1998.
- [81] Morid, M.A., Borjali, A., Del Fiol, G. A scoping review of transfer learning research on medical image analysis using ImageNet. *Comput Biol Med*. 128 (2021): 1-39, 2020.
- [82] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 7-12 June 2015, Boston, USA, pp. 1-9, 2015.
- [83] E, Karthik. A Framework for Fast Scalable BNN Inference using googlenet and transfer learning. 2021. *arXiv:2101.00793*
- [84] Chen, P., Agarwal, C., Nguyen, A. The shape and simplicity biases of adversarially robust ImageNet-trained CNNs. *arXiv:2006.09373*

- [85] He, K., Zhang, X., Shaoqing, R., Sun, J. Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA, pp. 770-778, 2016.
- [86] Simonyan, K., Zisserman, A. Very deep convolutional networks for large-scale image recognition. 2015. arXiv:1409.1556
- [87] Huang, X., Zhu, D., Zhang, F., Liu, T., Li, X., Zou, L. Sensing population distribution from satellite imagery via deep learning: model selection, neighboring effect, and systematic biases, 2021.arXiv 2103.02155
- [88] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. Densely Connected Convolutional Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21-26 July 2017, Honolulu, HI, USA, pp. 2261-2269, 2017.
- [89] Lopes, V., Gaspar, A., Luís, A., Cordeiro, J. An AutoML-based approach to multimodal image sentiment analysis. 2021, arXiv:2102.08092
- [90] Singh, J.; Shekhar, S. Road damage detection and classification in smartphone captured images using Mask R-CNN. IEEE International Conference On Big Data Cup 10-13 Dec. 2018, Seattle, WA, USA, 2018. arXiv:1811.04535
- [91] Chen, Q., Gan, X., Huang, W., Feng, J., Shim, H. Road damage detection and classification using mask r-cnn with densenet backbone. *Comput Mater Contin.* 65 (3): 2201–2215, 2020.
- [92] Hayashi K, Kapatkin AS (2012). Fractures of the tibia and fibula, 999-1014. In: KM Tobias, SA Johnston (Eds), *Veterinary Surgery Small Animal. Volume One, E-BOOK: 2-Volume Set*, Elsevier Inc., Canada
- [93] Tzotalin. LabelImg. Git code. <https://github.com/tzotalin/labelImg>. (Erişim tarihi: 27, 2020).

[94] Gulli, A., Pal, S. Deep learning with Keras. Packt Publishing Ltd. Birmingham, UK, 2017.

[95] Anonim. Tensorflow object detection API

[https://github.com/tensorflow/models/tree/master/research/object\\_detection](https://github.com/tensorflow/models/tree/master/research/object_detection) (Erişim tarihi: 17.12.2019)

[96] He, K., Gkioxari, G., Dollar, P., Girshick, R. Mask R-CNN. 2980-2988. In: IEEE International Conference on Computer Vision (ICCV). Venice, Italy, pp. 2980-2988, 2017.

[97] Understanding mean average precision for object detection (with Python Code)

<https://medium.com/analytics-vidhya/map-mean-average-precision-for-object-detection-with-simple-python-demonstration-dcc7b3850a07> (Erişim tarihi: 18.12.2019)

[98] Rani, S., Kumari, M., Amulya, G., Pothineni, E., Pavani, V., Reddy, S. 2019. Leg bone fracture segmentation and detection using advanced morphological techniques. Int j recent technol. 8 (2S3): 1246-1249.

[99] Tychsen-Smith, L., Petersson, L. Improving object localization with fitness nms and bounded iou loss. Proceedings of the IEEE conference on computer vision and pattern recognition, 18-23 June 2018, Salt Lake City, UT, USA, pp. 6877-6885, 2018.

[100] Ravi, D., Wong C, Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., Yang, G-Z. Deep learning for health informatics. IEEE J Biomed Health Inform, 21 (1): 4-21, 2017.

[101] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C-Y., Berg, A.C. SSD: Single Shot MultiBox Detector.

arXiv:1512.02325 [cs.CV]. <https://arxiv.org/pdf/1512.02325.pdf>.

[102] Baydan, B., Barışçı, N., Ünver, H.M. Determining the location of tibial fracture of dog and cat using hybridized Mask R-CNN architecture. *Kafkas Univ Vet Fak Derg*, (Article in press), 2021.

[103] Tsuruoka, Y., Tsujii, J. Boosting precision and recall of dictionary-based protein name recognition. *Proceedings of the ACL 2003 workshop on Natural language processing in biomedicine*. Sapporo, Japan, pp. 41-48, 2003.

[104] Battula, B.P., Balaganesh, D. Medical image data classification using deep learning based hybrid model with CNN and Encoder. *Rev d'Intelligence Artif*. 34 (5): 645-652, 2020. DOI: 10.18280/ria.340516

[105] Kalmet, P.H.S., Sanduleanu, S., Primakov, S., Wu, G., Jochems, A., Refaee, T., Ibrahim, A., Hulst, L.V., Lambin, P., Poeze, M. Deep learning in fracture detection: a narrative review. *Acta Orthop*. 91 (2): 215-220, 2020. DOI: 10.1080/17453674.2019.1711323

[106] Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L.H., Aerts, H.J.W.L. Artificial intelligence in radiology. *Nat Rev Cancer*. 18 (8): 500–510, 2018. DOI: 10.1038/s41568-018-0016-5

[107] Pak, U., Kim, C., Ryu, U., Sok, K., Pak, S. A hybrid model based on convolutional neural networks and long short-term memory for ozone concentration prediction. *Air Qual Atmos Health*. 11 (3): 883-895, 2018. DOI: 10.1007/s11869-018-0585-1

[108] Miskovic, V. Machine learning of hybrid classification models for decision support. *Sinteza 2014. Impact of Internet on Business Activities in Serbia and Worldwide*, Belgrade, Serbia, pp. 318-323, 2014.

[109] Bemani, A., Baghban, A., Mosavi, A., Shahab, S. Estimating CO<sub>2</sub>-Brine diffusivity using hybrid models of ANFIS and evolutionary algorithms. *Eng Appl Comput Fluid Mech*. 14 (1): 818-834, 2020. DOI: 10.1080/19942060.2020.1774422

[110] Jafarifarmand, A., Badamchizadeh, M.A., Khanmohammadi, S., Nazari, M.A., Tazehkand, B.M. Real-time ocular artifacts removal of EEG data using a hybrid ICA-ANCA approach. *Biomed Signal Process Control*. 31 (2017): 199-210, 2017. DOI: 10.1016/j.bspc.2016.08.006

[111] Golmohammadi, M., Torbati, A.H.H.N., Diego, S.L., Obeid, I., Picone, J. Automatic analysis of EEGs using big data and hybrid deep learning architectures. *Front Hum Neurosci*. 13 (76): 1-14, 2019. DOI: 10.3389/fnhum.2019.00076

[112] Olczak, J., Fahlberg, N., Maki, A. Razavian, A.S., Jilert, A., Stark, A., Sköldenberg, O., Gordon, M. Artificial intelligence for analysing orthopaedic trauma radiographs. *Acta Orthop*. 88 (6): 581-586, 2017.

## ÖZGEÇMİŞ

Adı Soyadı : Berker BAYDAN

Yabancı Dil : İngilizce

Eğitim Durumu : (Kurum ve Yıl)

Lisans : Atılım Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü (2010)

Yüksek Lisans : Umea Üniversitesi - İsveç, Bilgisayar Bilimleri (2013)

Doktora : Kırıkkale Üniversitesi, Bilgisayar Mühendisliği ABD (2021)

Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar:

(2013- Halen) : Havelsan A.Ş.

Yayınları (SCI) : Baydan Berker, Ünver Halil Murat, "Detection of Tibial Fractures in Cats and Dogs with Deep Learning", Ankara Üniversitesi Veteriner Fakültesi Dergisi (2020)

Baydan Berker, Barışçı Necaattin, Ünver Halil Murat, "Determining the Location of Tibial Fracture of Dog and Cat using Hybridized Mask R-CNN Architecture", Kafkas Üniversitesi Veteriner Fakültesi Dergisi (2021)

Yayınları (Diğer) : Surie Dipak, Baydan Berker, Lindgren Helena, "Proxemics Awareness in Kitchen AS-APAL: Tracking Objects and Human in Perspective", In 9th International Conference on Intelligent Environments, IEEE, (2013): 157-164.

Garousi Vahid, Afzal Wasif, Çağlar Adem, Işık İhsan Berk, Baydan Berker, Çaylak Seçkin, Boyraz Ahmet Zeki, Yolaçan Burak, Herkiloğlu Kadir, “Comparing automated visual GUI testing tools: an industrial case study”, 8th ACM SIGSOFT International Workshop, (2017)

Baydan Berker, Ünver Halil Murat, “Dataset Creation and SSD Mobilenet V2 Performance Evaluation For Dog Tibia Fracture Detection”, II.International Ankara Conference of Scientific Research, (2020): 433-443.

Garousi Vahid, Afzal Wasif, Çağlar Adem, Işık İhsan Berk, Baydan Berker, Çaylak Seçkin, Boyraz Ahmet Zeki, Yolaçan Burak, Herkiloğlu Kadir , “Visual GUI testing in practice: An extended industrial case study”, arXiv:2005.09303, (2020)