

**KOCAELİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**DERİN ÖĞRENME ALGORİTMALARI İLE BİYOMEDİKAL**  
**GÖRÜNTÜLERDEN ANOMALİ TESPİTİ**

**CANTEKİN ÇELİKHASI**

**KOCAELİ 2020**

**KOCAELİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLİŞİM SİSTEMLERİ MÜHENDİSLİĞİ**  
**ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**DERİN ÖĞRENME ALGORİTMALARI İLE BİYOMEDİKAL**  
**GÖRÜNTÜLERDEN ANOMALİ TESPİTİ**

**CANTEKİN ÇELİKHASI**

**Prof.Dr. Mehmet Melih İNAL**  
**Danışman, Kocaeli Üniversitesi** .....

**Doç.Dr. Devrim AKGÜN**  
**Jüri Üyesi, Sakarya Üniversitesi** .....

**Dr.Öğr.Üyesi Serdar SOLAK**  
**Jüri Üyesi, Kocaeli Üniversitesi** .....

**Tezin Savunulduğu Tarih: 20.05.2020**

## ÖNSÖZ VE TEŞEKKÜR

Yüksek lisans eğitimim boyunca benden yardımlarını esirgemeyen, akademik ve sosyal anlamda bana örnek olan ve doğru yolu gösteren akademik danışman hocam Prof. Dr. Mehmet Melih İNAL'a teşekkür ederim.

Her zaman yanımda oldukları ve destekledikleri için eşime, kızıma ve arkadaşlarıma teşekkür ederim.

Nisan 2020

Cantekin ÇELİKHASI

## İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ .....	v
SİMGELER VE KISALTMALAR DİZİNİ .....	vi
ÖZET.....	vii
ABSTRACT.....	viii
GİRİŞ .....	1
1. GENEL BİLGİLER.....	3
1.1. Çalışmanın Amacı .....	3
1.2. Literatür Taraması .....	3
2. DERİN ÖĞRENME .....	9
2.1. Yapay Sinir Ağları .....	9
2.1.1. Yapay sinir ağlarında öğrenme .....	10
2.2. Evrimsel Yapay Sinir Ağları .....	12
2.2.1. Evrim katmanı .....	12
2.2.2. Havuzlama katmanı .....	15
2.2.3. Düzleştirme .....	16
2.2.4. Tam bağlantı katmanı .....	16
2.3. Derin Öğrenme Modelleri .....	16
2.3.1. Resnet.....	16
2.3.2. U-net .....	18
2.3.3. Mask r-cnn .....	19
2.3.4. Yolov3 .....	20
2.4. Değerlendirme Metrikleri.....	22
2.4.1. Karışıklık matrisi .....	22
2.4.2. Doğruluk değeri .....	22
2.4.3. Kesinlik değeri .....	23
2.4.4. Duyarlılık değeri .....	23
2.4.5. F1-ölçümü değeri.....	23
2.4.6. AP ve map değeri.....	24
2.4.7. Cohen Kappa değeri.....	24
3. MATERYAL.....	27
3.1. Kullanılan Veri Kümleri.....	27
3.1.1. Mura.....	27
3.1.2. Edd2020 .....	28
3.2. Kullanılan Materyal.....	29
3.2.1. Donanım.....	29
3.2.2. Yazılım.....	29
4. YÖNTEM VE BULGULAR.....	30
4.1. Humerus Ön Kol kemiğinde Anomali Tespiti .....	30

4.1.1. Humerus pazu kemiğinde anomali tespiti sonuçları .....	32
4.2. Endoskopi Görüntülerinde Anomali Tespiti .....	32
4.2.1. Endoskopi görüntülerinde anomali tespiti sonuçları .....	34
4.3. Endoskopi Görüntülerinde Bölütleme.....	34
4.3.1. U-net kullanılarak yapılan uygulama.....	35
4.3.2. Mask r-cnn kullanılarak yapılan uygulama .....	37
4.3.3. Endoskopi görüntülerinde bölütleme sonuçları .....	38
5. SONUÇLAR VE ÖNERİLER .....	40
KAYNAKLAR .....	42
KİŞİSEL YAYINLAR VE ESERLER .....	48
ÖZGEÇMİŞ .....	49



## ŞEKİLLER DİZİNİ

Şekil 1.1	(a) Kurbağa Xenopus Türü Böbrek Görüntüsü (b) 3D U-Net bölütleme sonucu.....	6
Şekil 1.2	Arı ve arkadaşının önermiş olduğu yöntemin çalışma prensibi .....	7
Şekil 1.3	Budak'ın önerdiği yöntemin çalışma prensibi .....	7
Şekil 2.1	(a) Biyolojik Sinir Yapısı, (b) Yapay Sinir Yapısı.....	10
Şekil 2.2	Makine Öğrenmesi Yöntemleri.....	11
Şekil 2.3	LeNet-5 e ait ESA mimari modeli .....	12
Şekil 2.4	Lena Resmi (a) Orijinal görsel, (b) Canny filtresi uygulanmış görsel.....	13
Şekil 2.5	Filtre uygulaması,.....	13
Şekil 2.6	ReLU fonksiyonu.....	15
Şekil 2.7	Özellik matrisinin 2x2 havuzlama filtresinin uygulanması.....	15
Şekil 2.8	ResNet Blok (a) Klasik ESA bloğu (b)ResNet bloğu.....	17
Şekil 2.9	ResNet ve standart bir derin öğrenme modeli .....	17
Şekil 2.10	U-Net mimarisi.....	18
Şekil 2.11	Mask R-CNN mimarisi .....	19
Şekil 2.12	Mask R-CNN in ilk aşaması maskelenmiş son görüntü .....	19
Şekil 2.13	Sınırlayıcı kutu konum tahmini .....	20
Şekil 2.14	Mimarilerin başarılarının COCO mAP <sub>50</sub> veri Kümesi üzerinden karşılaştırılması.....	21
Şekil 2.15	Kesinlik – Hassasiyet grafiği.....	24
Şekil 3.1	MURA veri setinden seçilmiş görüntüler.....	28
Şekil 3.2	EDD2020 veri setinden seçilmiş görseller.....	28
Şekil 4.1	Önerilen ESA'nın mimarisi.....	30
Şekil 4.2	Model eğitim sonuç grafiği.....	31
Şekil 4.3	Test için tutulan veri setinde rastgele seçilmiş 20 adet X-RAY görüntüsünü sınıflandırılması.....	31
Şekil 4.4	YOLOv3 Model eğitim sonuç grafiği.....	33
Şekil 4.5	EDD2020 veri setinden rastgele seçilmiş 7 görüntü ve maske referansı.....	34
Şekil 4.6	Gerçek Referans Değer Görüntüsü (a) Normal Görüntü, (b) Etiketli görüntü, (c) Etiket görüntüsü.....	35
Şekil 4.7	Model Eğitim Sonuç Grafiği.....	36
Şekil 4.8	U-Net modelinin test verilerinden rastgele seçilmiş görüntüler ve bölütleme uygulaması.....	36
Şekil 4.9	Model Eğitim Sonuç Grafiği.....	37
Şekil 4.10	Mask R-CNN kullanılarak eğitilmiş modelin test verilerinden rastgele seçilmiş görüntüler üzerindeki bölütleme uygulaması .....	38
Şekil 4.11	U-Net Mask R-CNN tahmin karşılaştırılması (a) Orijinal Görüntü (b) Gerçek Referans Maske (c)U-Net tahmini (d)Mask R-CNN tahmini.....	39

## TABLULAR DİZİNİ

Tablo 2.1	Biyolojik ve Yapay Sinir Hücrelerinin.....	10
Tablo 2.2	Elektron Mikroskopu Bölütleme Yarışması sonuçları .....	18
Tablo 2.3	Mimarilerin başarılarının Karşılaştırılması .....	21
Tablo 2.4	Karışıklık Matrisi. ....	22
Tablo 3.1	MURA veri seti içeriği.....	27
Tablo 4.1	MURA veri seti başarımların karşılaştırması. ....	32
Tablo 4.2	MURA veri seti başarımların karşılaştırması. ....	32
Tablo 4.3	EDD2020 veri setinin, YOLOv3 mimarisi kullanılarak yapılan eğitimin test sonuçları. ....	33
Tablo 4.4	YOLOv3 EDD2020 veri seti eğitim sonuçları.....	34
Tablo 4.5	Mask R-CNN, U-Net sonuç karşılaştırması.....	38

## SİMGELER VE KISALTMALAR DİZİNİ

$\theta$	: Polarma değeri
$\Sigma$	: Toplam sembolü

### Kısaltmalar

AP	: Average Precision (Ortalama Hassasiyet)
BESA	: Bölgesel Evrişimsel Sinir Ağı
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
DICOM	: Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)
DL	: Deep Learning (Derin Öğrenme)
EDD2020	: Endoscopy Disease Detection and Segmentation 2020 (Endoskopi Görüntülerinde Teşhis koyma ve Bölütleme 2020)
EM	: Elektron Mikroskopu
ESA	: Evrişimsel Sinir Ağları
FCNN	: Fully Convolutional Neural Network (Tam Evrişimli Sinir Ağı)
FPS	: Frame Per Second (Saniyede İşlenen Çerçeve Sayısı)
GPU	: Graphical Processor Unit (Grafik İşlem Ünitesi)
IOU	: Intersection over Union (Birlik Üzerinde Kesişim Metriği)
KL	: Kellgren & Lawrence
MAP	: Mean Average Precision (Ortalama Hassasiyetlerin Ortalaması)
MSE	: Mean Squared Error (Ortalama Kare Hata)
OA	: Osteoartritinin
R-CNN	: Region Based Convolutional Neural Network (Bölgesel Evrişimsel Sinir Ağı)
ReLU	: Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
RMSE	: Root Mean Squared Error (Ortalama Hata Kare Kökü)
SGD	: Stochastic Gradient Descent (Stokastik Gardiyan İniş)
TL	: Transfer Learning (Öğrenme Aktarması)
X-RAY	: X-Işınları (Röntgen)
YSA	: Yapay Sinir Ağları



# DERİN ÖĞRENME ALGORİTMALARI İLE BİYOMEDİKAL GÖRÜNTÜLERDEN ANOMALİ TESPİTİ

## ÖZET

Tıbbi görüntülerdeki anomalilerin bilgisayar destekli tespiti büyük öneme sahiptir. Bu alanda yapılan birçok araştırmaya rağmen, aşılması gereken birçok problem yeni çalışmalara kapı aralamaktadır. Bu çalışmanın amacı, Derin Öğrenme yöntemlerini kullanarak medikal görüntüler üzerinden tam otomatik olarak anomali tespiti yapmak ve sınıflandırmaktır. Ayrıca bu işlemi yaparak radyologlar üzerinde biriken yükü azaltmak ve insan hatasını asgari orana indirmektir. Çalışmada MURA (Stanford X-RAY kemik görüntüsü veri seti) ve EDD2020 (Endoskopi Hastalığı Tespiti ve Bölütleme yarışması) veri seti olarak kullanılmıştır. Bu veri setleri üzerinden Tensorflow ve Darknet kütüphaneleri üzerinden Mask R-CNN, YOLOv3, ResNet ve U-Net mimarileri kullanılarak derin öğrenme modelleri eğitilmiştir. Humerus (pazu kemiği) kemiklerinin X-RAY görüntüleri üzerindeki anomalilerinin tespiti için tasarlanan 12 ResNet bloğuna sahip modelde, test verilerindeki anomali tahminleri Cohen Kappa metriği ile 0,9568 oranında başarımla elde etmiştir. YOLOv3 mimarisi ile EDD2020 veri kümesi üzerine eğitilmiş modelin F1- Doğruluk Ölçümü 0,46, ortalama hassasiyetin ortalaması mAP skoru ise 0,37 oranında kalmıştır. Endoskopi görüntülerinde anomali tespiti ve bölütleme için Mask R-CNN ve U-Net mimarileri kullanılarak iki ayrı model geliştirilmiştir. Mask R-CNN’de oluşturulan modelin AP skoru 0,20; U-Net’te oluşturulan modelin AP skoru ise 0,83 oranındadır. Gerçekleştirilen tüm yöntemler, radyoloji uzmanlarının yükünü azaltarak yol gösterici bir araç olarak önerilmektedir.

**Anahtar Kelimeler:** Derin Öğrenme, Evrimsel Sinir Ağı, Medikal Görüntülerde Anomali Tespiti, Medikal Görüntülerde Bölütleme, Yapay Sinir Ağları.

## **ANOMALY DETECTION THROUGH DEEP LEARNING ALGORITHMS AND BIOMEDICAL IMAGES**

### **ABSTRACT**

The computer aided detection of anomalies in medical images has great importance. Many problems, which need to be overcome, lead to new studies despite many researches in this area. The aim of this study is to detect and classify abnormalities fully automatically on medical images using Deep Learning methods. In addition, it is to reduce the burden accumulated on radiologists and to minimize human error in the process. In the study, MURA (Stanford Bone X-Ray Dataset) and EDD2020 (Endoscopy Disease Detection and Segmentation) were used as dataset. Through these datasets, deep learning models were trained using Mask R-CNN, YOLOv3, ResNet and U-Net architectures over Tensorflow and Darknet libraries. The model with 12 ResNet blocks, designed for the detection of anomalies on the X-RAY images of the Humerus bones, has achieved 0,9568 success with the Cohen Kappa metric in the test data. With the YOLOv3 architecture, the model trained on EDD2020 dataset has an F1-Score of 0,46 and a mAP score of 0,37. Two different models have been developed by using Mask R-CNN and U-Net architectures for anomaly detection and segmentation in endoscopy images. The AP score of the model created in Mask R-CNN is 0,20; and the AP score of the model created in U-Net is 0,83. All performed methods are suggested as a guiding tool by reducing the burden of radiologists.

**Keywords:** Deep Learning, Convolutional Neural Networks, Anomaly Detection in Medical Images, Segmentation in Medical Images, Artificial Neural Network.

## GİRİŞ

Yapay zekâ kavramının gelişmesi ve kayda değer başarılar alması ile birlikte yapay zekânın her meslek alanında insanın yerini alabileceği gibi bir yanlış yaygın bir şekilde varlığını sürdürmektedir [1]. Ancak böyle bir yanlışın gereksiz olduğu varsayılabilir. Aslında yapay zekâ sistemleri her mesleğin yerini almayacak, insanları gereksiz rutin işlerden kurtarıp, daha değerli işlere vakit ayırması için zaman kazandıracaktır [2, 3].

Pablo Picasso, “Bilgisayarlar faydasız, sadece size yanıt verebilirler.” demiştir [4]. Bilgisayarların insan gibi soru sorması veya yaratıcı düşünmesi beklenemez, çünkü insanlar birbirlerini şaşırtma, hayretler içinde bırakma, birbirlerinde merak ve kuşku uyandırma arayışı içindedirler. Birbirimiz için sergilediğimiz bu davranışlar devrelerimize kazınmış olduğu için başkalarında da yine bu özellikleri ararız [5]. Bilgisayarların yaratıcı olmamalarının nedeni budur. Girdi olarak ne koyarsanız çıktı olarak verdikleri de aynı oranda olacaktır. Bilgisayar zekâsının böylesi mekanik olması ve sadece öğretilmiş yanıtları vermesi bu sebeptendir [5]. Picasso’nun bu tespitinin son kısmı doğrudur, zaten bilgisayarların yaratıcı olmaları beklenmiyor. Ancak bizim onlara öğrettiğimiz rutin şeyleri kusursuzca yapıp ve bizleri büyük yüklerden kurtarmaları temel amaçlarıdır [4]. Örneğin bir radyoloğun işini düşünecek olursak, bir röntgeni okuması, radyoloğun bu iş için gerekli görülen donanımın kullanımında harcayacağı vakti en asgari düzeye indirme imkânına sahip olacaktır. Ayrıca, meslektaşları ile görüş alışverişi yapması ve operasyon planlaması, hastalarla iletişim kurması gibi daha önemli sayılabilecek görevlere daha fazla vakit ayırması için de imkân bulacaktır [2, 6]. Bu tür yardımları yapmasını planladığımız yapay zekâ otomasyonlarının saçma hatalar yapma olasılıkları da oldukça yüksektir. Örneğin yapay zekâ ile geliştirilmiş bir tanı koyma otomasyonunun bazı hastalara doktorların asla koymayacağı yanlış bir tanıyı koyma olasılığı vardır [7]. Ancak yine de en iyi sistemi oluşturmaktan geri durulmamalı ve insan bilgisayar etkileşiminin verimli şekilde kurgulandığı melez (hibrit) sistemler kurulmalıdır [7].

12 farklı sektörden 1075 şirketin katıldığı bir araştırmada, insan-yapay zekâ işbirliğinin kurulduğu şirketlerde başarının arttığı gözlemlenmiştir [8]. Tıbbi görüntü analizi şu anda yapay zekâdaki gelişmeler nedeniyle bir dönüşüm yaşamaktadır [9]. Tıbbi görüntülerdeki anormalliklerin bilgisayar destekli tespiti büyük öneme sahip olmaya başlamıştır. Bu alanda yapılan birçok araştırma olsa da, hâlihazırda aşılması gereken birçok problem de pek çok farklı yeni çalışmaya kapı aralamıştır [10]. Öyle ki bu durum son zamanlarda Tıbbî Görüntüleme Topluluğunun (Medical Imaging with Deep Learning - MIDL) o kadar ilgisini çekmiştir ki [10], bu topluluk derin öğrenme ile tıbbî görüntüleme konusunda yıllık düzenlenen özel bir konferans organize etmektedir [11]. 2018’de ilki yapılan bu organizasyona NVidia, Google, Microsoft, Canon, Amazon gibi yapay zekâyâ yatırım yapan firmalar destekleyici olmuşlardır. 2019 yılında yapılan konferansta 47 makale ve 105 bildiri yayımlanmıştır [11].

Pek çok farklı çalışmada genel olarak aynı sınıf görüntüler üzerine çalışırken [12-16], bu tez çalışmasında üç farklı yöntem denenmiştir. Birinci yöntemde insan kol kemiği X-Ray görüntülerinde otomatik olarak anomalilik tespiti; ikinci yöntemde, gerçek zamanlı endoskopi görüntüleri üzerinden anomalinin tespiti ve konumlandırılması; üçüncü yöntemde ise endoskopi görüntülerinde bölütleme yapılacaktır.

Tez çalışmasının geri kalan bölümlerinin kapsamı ise şöyledir: Bölüm 2’de medikal görüntüler üzerine yapılan çalışmalar incelenmiş; Bölüm 3’te, çalışmada kullanılan temel algoritmalar açıklanmış; Bölüm 4’te, kullanılan veri kümeleri ve donanımlar incelenmiştir. Bölüm 5’te ise önerilen yöntemler incelenip uygulamaları gerçekleştirilmiştir. Son bölümde de önerilen yöntemlerin sonuçları ile daha önceki çalışmaların sonuçları karşılaştırılmış, çalışmanın geliştirilmesi için ileride yapılacak araştırmalara yönelik önerilerde bulunulmuştur.

## 1. GENEL BİLGİLER

Bu bölümde tez çalışmasının genel amacı sunularak önceki çalışmalara değinilmiştir. Ayrıca, bu bölümde, yapılan literatür taramasının detayları yer almaktadır.

### 1.1. Çalışmanın Amacı

Bu çalışmasının öncelikli amacı, Derin Öğrenme yöntemlerini kullanarak medikal görüntüler üzerinden tam otomatik olarak anormallik tespiti yapmaktır. Bunun yanı sıra alt amaçları ise şu şekilde sıralanabilir:

- X-ray görüntülerinde aykırılık tespiti
- Gerçek zamanlı endoskopi görüntülerde aykırılıkların sınıflandırması
- Endoskopi görüntülerinde aykırılık bölgesinin bölütlenmesi

### 1.2. Literatür Taraması

Stanford üniversitesinden MURA veri setini hazırlayan ekip, oluşturdukları veri setini 169 katmanlı bir DenseNet Evrişimsel Sinir Ağları (ESA) ile eğitmiş, 0,81 hassasiyet ve 0,88 doğruluk oranına erişmişlerdir. Çalışmalarını Cohen'in kappa katsayısı [17] metriği ile radyoloji uzmanlarından oluşan üç ayrı grubun sonuçları ile karşılaştırmışlardır. Bu karşılaştırma sonucunda model performansı el, ön kol, pazu kemiği, omuz, dirsek kemiklerindeki başarımları en iyi uzman hekim grubu başarımindan düşük çıkmıştır [12].

Ramya Bagavath Singh ve arkadaşları 2019 yılında X-RAY görüntülerinin sınıflandırılma ve konumlandırılmasındaki zorluklara dayanarak yaptıkları çalışmada farklı bir derin öğrenme yapısı öne sürmüşlerdir. Yaptıkları bu çalışmayı MURA veri setine uygulamak için MURA veri setinin sahip olduğu 7 ayrı sınıf için her birine ayrı birer DL (Derin Öğrenme) geliştirmişlerdir. Çalışmanın sonucunda oluşturulan 8 ayrı DL modelinde ortalama olarak 0,80 başarımlar elde etmişlerdir [14].

Obioma Pelka ve arkadaşları 2019 yılında gerçekleştirdikleri X-RAY verilerinin tam otomatik olarak etiketlendirilmesi ve sınıflandırmasına yönelik çalışmaları iki ana kısımdan oluşmaktadır. İlk kısım görüntü için etiketler üretirken, ikinci kısımda ise aykırılık tespiti yapmaktadır. Çalışmalarının sonuçlarını göstermek için MURA veri seti üzerine uygulanmıştır. Bu uygulama sonucunda çalışmalarının ilk kısmı yani sınıfına dair etiket üretimi stokastik gardiyan inişi (SGD) metrik hesaplama yöntemi ile 0,95'lik bir başarıma ulaşırken, çalışmanın ikinci kısmı olan aykırılık tespiti ise ortalama karesel hata karekökü (RMSE) metrik hesaplama yöntemi ile 0,81'de kalmıştır [13].

Kermi ve arkadaşları 2019 yılında U-Net mimarisinden esinlenerek Derin ESA'yı geliştirmişlerdir. Geliştirdikleri ESA ile beyin 3D MR görüntüleri üzerinden tam otomatik olarak tümör bölütleme işlemini amaçlıyorlardı. Çalışmalarını Pennsylvania Üniversitesi Perelman Tıp Okulunun düzenlediği BraTS'2018 yarışmasının veri setine uygulayarak Dice katsayısı hesaplamasına göre tümör bölgesi için 0,86; tümör çekirdeği için 0,805 başarımlar elde etmişlerdir [18].

Luke Oakden-Rayner, 2019'da, herkesin erişimine açık olan radyoloji veri setlerine ait etiketlenme işlemindeki detay ve hassasiyetin, makine öğrenmesi için ne denli önemli olduğuna dair bir öneride bulunmuşlardır. Bu önerilerini birkaç radyoloji yarışması veri setine uygulamışlardır. En iyi sonucu Stanford Üniversitesi makine öğrenmesi grubunun derlediği MURA veri setinde almışlardır. MURA veri setine ait rastgele 714 çalışma seçilmiş ve bu veri seti yeniden etiketlenmiştir. Çalışma sonucunda MURA etiketleri daha doğru, ancak orijinal normal / anormal etiketler, %60 duyarlılık ve %82 özgüllük ile dejeneratif eklem hastalığı olan vakaların alt kümesi için yanlış çıkmıştır [19].

Pengcheng Xi ve arkadaşları 2019 yılında medikal çözüm için kullanılan ESA ağlarının eğitimi için farklı bir öneri sunmuşlardır. Genelde eğitim için görüntünün tamamı kullanılırken çalışmalarında her bir verinin tam görüntüsü yerine normalliklere odaklanan görüntü parçalarını kullanmışlardır. Böylelikle oluşturdukları bu anormallik detektörleri ile verilen görsellerde arama yapılabilmektedir. Çalışmalarını mamogram veri seti üzerinde test etmiş ve

geleneksel bir yaklaşımla %81,55'e kıyasla %92,53'lük bir genel sınıflandırma doğruluğu elde etmişlerdir [15].


2018 yılında Can'ın yaptığı çalışmada DICOM görüntülerden karaciğer dokusu ve hacmini hesaplamaya çalışmış ve görüntüleri üç boyutlu (3B) şekle dönüştürmüştür. Geliştirdiği algoritma ve uygulama ile karaciğer hacimlerinin tespiti için karaciğeri ifade eden piksel koordinatları arasındaki uzaklık değeri ve axial kesitler arasındaki uzaklık değerlerinin çarpımından bir sonuç elde etmiştir. Bu formülasyona göre 30 farklı hasta verisi üzerinden elde edilen sonuçlar ve uzman hekimler tarafından tespit edilmiş hacim karşılaştırması yapıldığında 0,95 oranında başarımla elde edilmiştir [16].

2015 yılında Yaniv Bar ve arkadaşları göğüs radyografisi verilerinde patoloji tespiti için derin öğrenme yaklaşımlarının gücünü inceleyerek ESA ile göğüs röntgeni görüntülerinde farklı patolojileri tanımlamaya çalışmışlardır. Çalışmalarını 93 X-RAY veri kümesinde test ederek sağ Plevral efüzyon tespiti için 0,93, büyümüş kalp tespiti için 0,89 ve sağlıklı ve anormal göğüs röntgeni arasında sınıflandırma için 0,79 eğri altında (AUC) bir başarımla elde edilmiştir [20].

Öğrenme aktarımı (Transfer Learning-TL) ve ince ayar (Fine-Tuning) yöntemleri, daha önceden eğitilmiş bir modelin ağırlıklarının üzerine yeni modeller inşa etmek için kullanılır. Bu yöntemlerin amacı eğitim maliyetlerini azaltmak ve buna ek olarak küçük veri kümelerine sahip modellerde başarımları arttırmaktır. Bu yöntemlerden faydalanana Antony ve arkadaşları tarafından ESA ile diz osteoartritinin (OA) şiddetini ölçmek için 2016'da yeni bir yaklaşım önerilmiştir. Klinik olarak OA şiddeti beş puanlık bir ölçek olan Kellgren&Lawrence (KL) puanlaması kullanılarak değerlendirilir. Radyolojik görüntülerde bu puanlamayı ESA kullanarak verebilmek için, X-RAY görüntüleri üzerinde Sobel kenar çıkarma algoritmasını ve karar destek makinelerin yöntemini (Support Vector Machine-SVM) kullanarak özellik çıkarımı yapılmış ve KL puanlamasını 5 ayrı seviyede sınıflandırılmıştır. Bu sınıflandırma sonucuna kullanılarak görüntülere etiketleme yapılmıştır. Hazırlanan çalışma önceden eğitilmiş ImageNet üzerine aktarılarak ortalama karesel hata (Mean Squared

Error - MSE) hesaplamasına göre %61 doğruluk elde edilerek iyileşme sağlanmıştır [21].

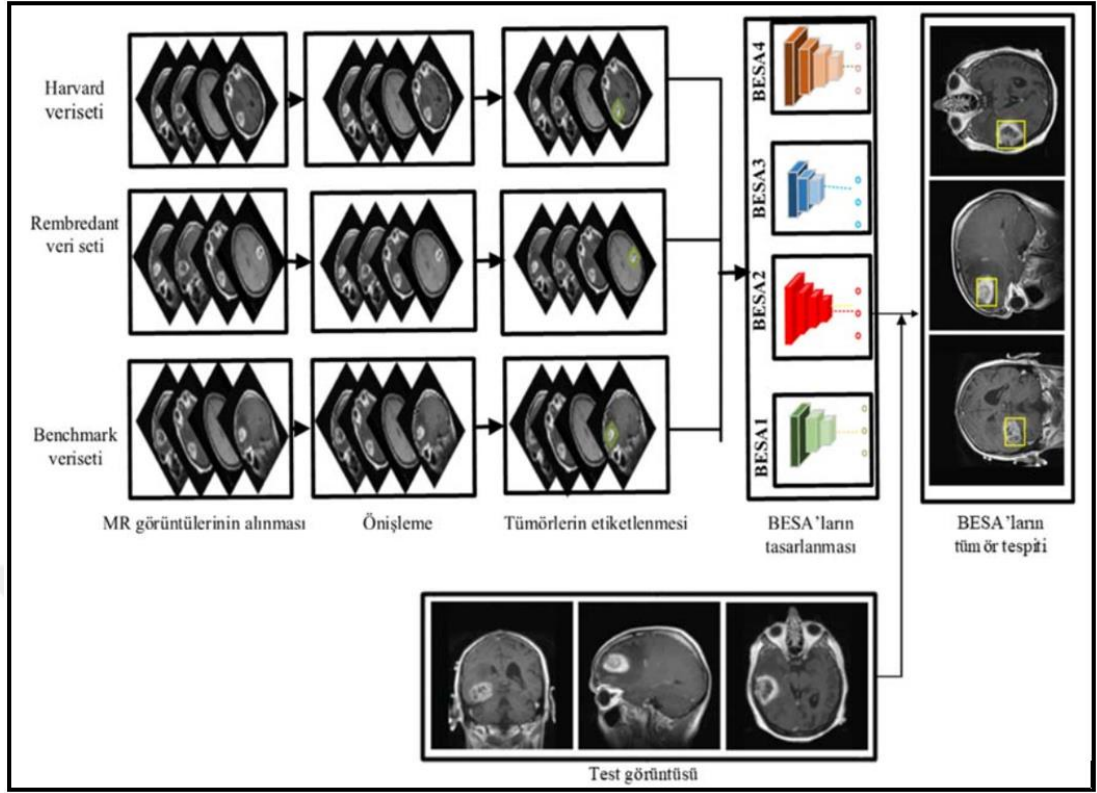
Çiçek ve arkadaşları tarafından 2016 yılında etiketlenmiş parçalı hacimsel medikal görüntülerinden öğrenen ve (3D) bölütleme yapan U-Net mimarisini esas alan ESA önerilmiştir. Öneri iki ana kısımdan oluşmaktadır. Birinci kısım kullanıcı parçalı görüntülerdeki bazı dilimleri etiketler ve ağ bu seyrek etiketlemelerden öğrenerek 3D bölütleme yapar. İkinci kısım ise tam otomatik olarak eğitim verilerini kullanarak oluşturulmuş bir model kullanılarak verilen görüntü üzerinde 3D bölütleme yapar. Önerileri bir kurbağa cinsi olan Xenopus türünün böbrek görüntüleri üzerinde test edilmiş, Şekil 1.1 birlik üzerinde kesişim metriği ile (Intersection over Union- IoU) 0,72 ortalama başarımla elde edilmiştir [22].



Şekil 1.1 (a) Kurbağa Xenopus Türü Böbrek Görüntüsü (b) 3D U-Net bölütleme sonucu.


Arı ve arkadaşı tarafından 2019 yılında beyin MR görüntülerinde tümör tespiti yapan bir bölgesel tabanlı ESA (BESA) geliştirilmiştir. Çalışmalarında Benchmark, Rembrandt ve Harvard veri setleri için 4 farklı BESA geliştirilmiş ve veriler üzerinden test edilmiştir. Her bir veri kümesi için öncelikle Manyetik Rezonans (MR) görüntülerde olabilecek gürültülerin etkilerini azaltmak için histogram germe işlemi uygulanmıştır. Veriler, yapılan bu ön işlemden sonra manuel olarak etiketlenmiştir. Eğitime hazır olan veriler, farklı katman sayılarına ve optimizasyon kuralına sahip olan BESA'larda eğitilmiştir Şekil 1.2. Eğitimler sonucunda en yüksek doğruluk değerine Benchmark veri kümesi üzerinde 4'üncü BESA ile %99,10 olarak erişilmiştir [23].





Şekil 1.2 Arı ve arkadaşının önermiş olduğu yöntemin çalışma prensibi [23].

Karaciğer nakillerinde, karaciğerin hacmini hesaplanması oldukça önemli ve doktorlar için uzun zaman alıcı bir işlemdir. 2019’da Budak, bu işlemi bilgisayarlı tomografi (BT) görüntüleri üzerinden otomatik olarak bölütleme ile yapabilen bir ESA modeli önermiştir Şekil 1.3 [24].



Şekil 1.3 Budak’ın önerdiği yöntemin çalışma prensibi [24].

Yöntemde, Dokuz Eylül Üniversitesi Tıp Fakültesinden sağlanan 20 hastaya ait BT görüntüleri kullanılmıştır. Bu verilerden 6 seti eğitim için kullanılırken 20 set hem eğitim hem de test için kullanılmıştır. Yöntemde ilk olarak BT görüntülerine bir ön işlem gerçekleştirilerek görüntülerin daha elverişli olması sağlanmıştır. Bu ön işlemde

görüntü içerisinde karaciğere ait olmayan kaburga, omurga, yağ dokusu gibi bölgeleri çıkarılmıştır. Ön işlemde geçmiş görüntüler 5 katmanlı ESA'da eğitilmiştir. Model bölütleme sonuçlarının doğruluğu hesaplanırken beş farklı değerlendirme ölçütü kullanılmıştır. Bu ölçütlerin 20 setinin test sonuçlarının ortalaması şu şekildedir: Hacimsel örtüşmede %88.43 oranında bir başarı elde edilmiştir [24].




## 2. DERİN ÖĞRENME

Derin öğrenme, birçok gizli katmana sahip Yapay Sinir Ağları (YSA) üzerine inşa edilmiş bir makine öğrenmesi algoritmasıdır [25]. Bu yöntem, ham veri üzerinden özellik çıkarımı ve bu çıkarımlardan elde edilen verilerin işlenmesi için birbirini takip eden bir mekanizmaya sahip olan ve en sonunda da bir yapay sinir ağını besleyen bir mimaridir [26]. Geçmiş 1965 yılına dayanmasına rağmen 2000'li yıllarda bir sektöre uğramış, 2006 yılından sonra oyun sektörü ile büyüyen ve gelişen Grafik İşleme Ünitesi (Graphics Processing Unit - GPU) dünyası; Microsoft, Facebook, Google gibi devlerin ARGE yatırımları sayesinde uygulanabilir hale gelmiştir [27-30]. Derin öğrenme yaklaşımları, yüz tanımda insanlardan daha iyi bir başarı elde etmiştir [31]. Medikal görüntüleme ile profesyonellerle yakın teşhis koyma ile ses tanıma ve metin okuma [32] gibi alanlarda gösterdiği başarıların yanında yakın zamanda GO oyununda dünya şampiyonunu yenmesini [33] dolayısıyla araştırmacılar derin öğrenme algoritmalarını her alana uygulamaya çalışmaktadırlar [30].

### 2.1. Yapay Sinir Ağları

1943 yılında McCulloch-Pitts modeli ile başlayan canlı organizmaların sinir yapılarının yapay olarak uyarlanması fikri o günden bugüne oldukça yol kat etmiştir [34]. Ancak, biyolojik sinir yapıları hakkında hala yeterli bilgiye sahip olunmamasına rağmen YSA biyolojik sinir sistemine benzetilerek gelişimine devam etmektedir. YSA ile biyolojik sinir sisteminin karşılaştırılması Tablo 2.1'de verilmiştir [35]. Şekil 2.1'de biyolojik ve yapay sinir hücresi yapıları görülmektedir [35].



Şekil 2.1 (a) Biyolojik Sinir Yapısı [36], (b) Yapay Sinir Yapısı.

Tablo 2.1 Biyolojik ve Yapay Sinir Hücrelerinin Benzerlik Tablosu [35].

Biyolojik Sinir	Yapay Sinir
Nöron	İşlem Elemanı
Dentirit	Toplama fonksiyonu
Hücre gövdesi	Transfer Fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar


Bir YSA hücresi modelinde, giriş verisi olan  $x_i$  değerleri,  $w_i$  ağırlık katsayılarıyla çarpılarak genellikle toplanır. Bazı modellerde çarpım işlemi de kullanılmaktadır. Modelin tüm farklı durumlarda çıkış üretmesini sağlamak için  $\theta$  polarma değeri de toplama katılarak,  $f(x)$  aktivasyon fonksiyonundan geçirilmesiyle sonuç elde edilir [37]. Denklem (2.1) ve (2.2)'de bu durum ifade edilmiştir:

$$y=f(w_1 \times x_1 + w_2 \times x_2 + \dots + w_n \times x_n + \theta) \quad (2.1)$$

$$y=f(\sum_{i=1}^n (w_i \times x_i) + \theta) \quad (2.2)$$

### 2.1.1. Yapay sinir ağlarında öğrenme

YSA yapılarında girilen verilere göre istenilen çıktıya ulaşmaya ağırlık öğrenmesi denir [38]. YSA'larda öğrenme danışmanlı, danışmansız ve takviyeli olmak üzere üç farklı yöntemle sahiptir.



Şekil 2.2 Makine Öğrenmesi Yöntemleri.

### 2.1.1.1. Danışmanlı öğrenme

Bu öğrenme stratejisinde, YSA eğitimi sırasında hem girdi verileri hem de çıktı verileri ağa tanımlanır. Böylelikle ağın bir hedef çıktı değeri bulunmaktadır. Bu stratejinin temeli, eğitim sırasındaki çıktılar ve hedef çıktılar arasındaki hatayı minimize edecek şekilde ağırlıkların yenilenmesini sağlamaktır [39] .

### 2.1.1.2. Danışmansız öğrenme

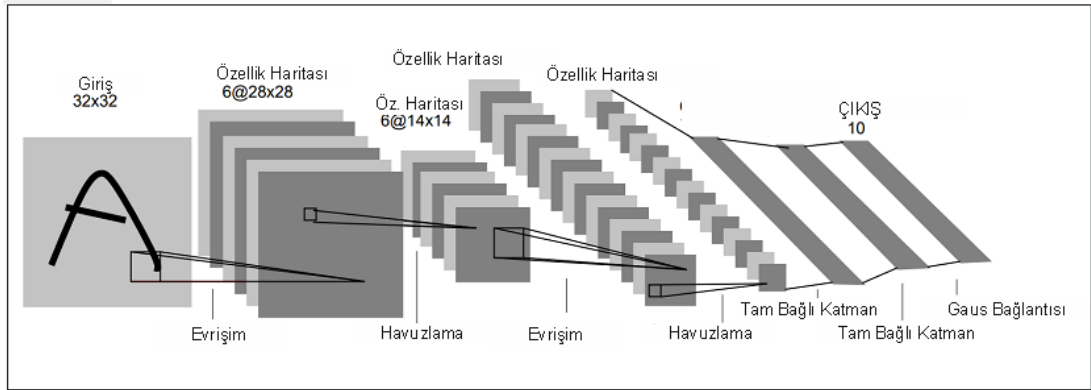
Danışmansız öğrenme stratejisinde YSA'ya sadece giriş verileri girilmekte ve herhangi bir hedef çıktı değeri verilmemektedir. Girdi olarak verilen verilerin kendi aralarında sınıflandırabilecek şekilde ağırlıkların organize edilerek YSA'nın belirli çıkışlarına dağıtılması beklenmektedir. Bu sayede aynı özelliklere sahip verilerin kümeleme işlemi gerçekleştirilmektedir [40].

### 2.1.1.3. Takviyeli öğrenme

Bu öğrenme stratejisi, denetimli öğrenmeye benzer, ancak YSA'nın her tekrarlama sonunda elde ettiği sonucu iyi ya da kötü olmasına göre sisteme ödül ya da ceza özelliği katarak belli kritik önem taşıyan girişler için ağın çıkışının hedef değerlerini sağlama stratejisini kullanır. Buradaki amaç, sistemin vermiş olduğu kararlardaki hataları azaltacak şekilde doğruların hatırlanmasını sağlayarak en iyi öğrenme değerlerine erişmektir [41].

## 2.2. Evrişimsel Yapay Sinir Ağları


Evrişimsel Sinir Ağları (ESA), genellikle çok boyutlu verileri işlemek için tasarlanmıştır [42]. 3 kanallı RGB piksel yoğunluklarını içeren 3 tane 2 boyutlu diziden oluşan bir görüntü bu işleme örnek gösterebilir. Dahası, günlük yaşamdaki çoğu veri ses ve video gibi dizi şeklindedir [42]. Şekil 2.3'te ESA mimarisi verilmiştir. Bu mimariye göre veri bir veya birkaç evrişim ve havuzlama katmanından geçtikten sonra bir tam bağlantılı katmana gelir ve sınıflandırma yapacak bir YSA ağına giriş olarak sunulur tüm bu işleyişin ardından bir sonuca varılır. Elde edilen sonuç, hedef değer ile karşılaştırılarak bir hata puanı oluşturulur ve bu hata puanı ağırlıklara dağıtılarak her iterasyonda hatanın azaltılması sağlanır [43, 44].



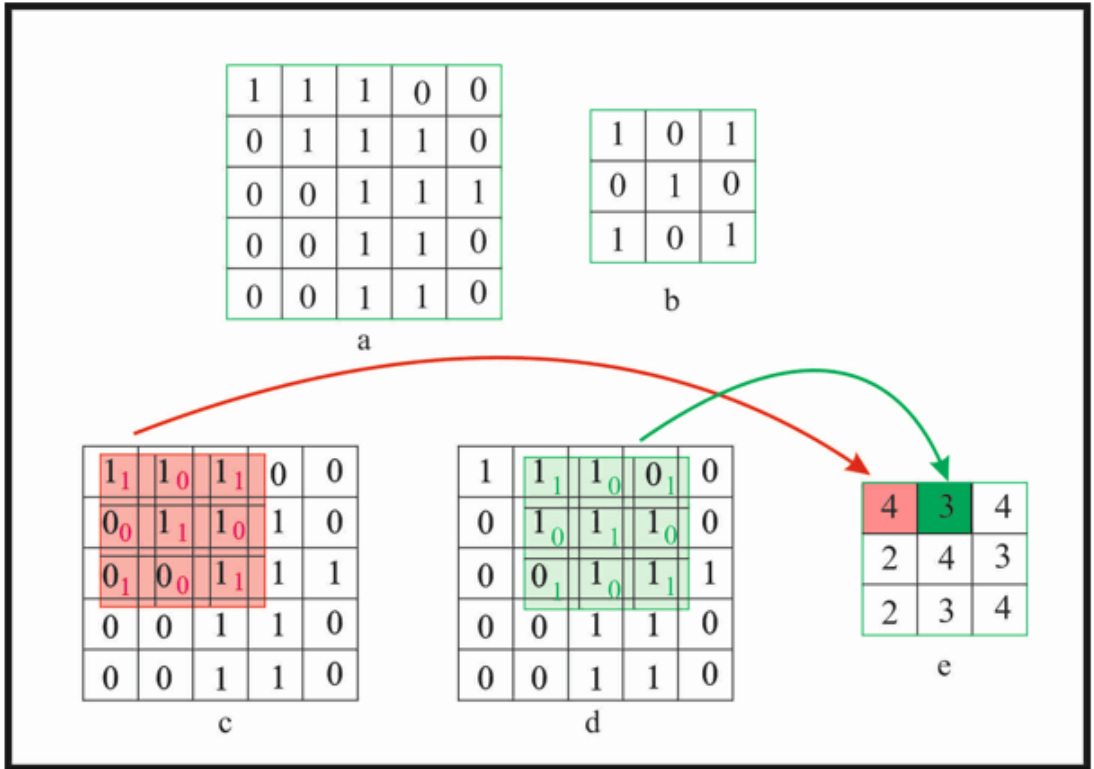
Şekil 2.3 LeNet-5 e ait ESA mimari modeli [45].

### 2.2.1. Evrişim katmanı

Evrişim katmanında, filtreler uygulanarak verinin öznitelik haritası çıkarılır [46]. Bu katmanda kenar bulma, piksel ekleme ve kaydırma adımı yaygın olarak kullanan filtrelerdir [47]. Kenar bulma filtresi, görsel veri setlerinde özellik çıkarmak için en çok kullanılan filtrelerden biridir [47]. Gabor [48], Prewitt [49], Sobel [50], Canny [51], Marr ve Hilderth [52] en çok tercih edilen kenar bulma algoritmalarıdır [53]. Şekil 2.4'te Canny filtresi uygulmuş ünlü Lena resmi görülmektedir. Bu filtreleme sayesinde görüntü üzerindeki nesnelerin fiziksel hatları belirlenmiş, görüntü üzerindeki gereksiz ayrıntılar minimuma düşürülmüştür.



Şekil 2.4 Lena Resmi (a) Orijinal görsel, (b) Canny filtresi uygulanmış görsel.



Şekil 2.5 Filtre uygulaması, (a) Orijinal görüntü matrisi, (b) Kenar filtre matrisi, (c) Özellik matrisinin ilk hücrenin hesaplanması, (d) Özellik matrisinin ikinci hücrenin hesaplanması, (e) Hesaplamalar sonucu oluşan özellik matrisi.

Kullanılan bu filtreler genelde çok boyutludur; kenar bulma filtresi için açıklayacak olursak. Şekil 2.5a gibi elimizde 5x5 boyutlarında bir görüntümüz ve Şekil 2.5b gibi 3x3 boyutunda bir de kenar bulma filtremiz olsun. Bu matrislerdeki her bir hücre bir pikseli ifade etmektedir. Kaydırma adım sayısı 1 piksel olarak belirlendiğinde; filtre matrisi, görüntü matrisi üzerinde kaydırma adım sayısı kadar gezdirilerek Şekil 2.5e'deki özellik haritası çıkartılmıştır [54].

Şekil 2.5 e'de filtre sonucunda oluşan özellik haritasının boyutu, filtrenin boyutuna bağlı olarak değişikliğe uğramaktadır.  $n \times n$  boyutunda bir görüntü için  $f \times f$  filtre uygulanırsa çıkış görüntüsünün boyutu  $r \times r$  Denklem (2.3)'teki gibi hesaplanır [55];

$$(r,r)=(n-f+1) \times (n-f+1) \quad (2.3)$$


Çıkış görüntüsünün boyutunun değişmemesi için piksel ekleme yapılarak; Denklem 2.4 uygulanarak, eksik pikseller 0 ya da en yakın komşularının ortalaması alınarak eklenir. Eklenen piksel  $p$  olarak ifade edilir ve işlemin gerçekleştirme sayısı da kaydırma adımı  $s$  olarak ifade edilerek Denklem (2.5)'e göre elde edilir [47];

$$p = \frac{(f-1)}{2} \quad (2.4)$$

$$\left[ \frac{(n+2p-f)}{s} + 1 \right] \times \left[ \frac{(n+2p-f)}{s} + 1 \right] \quad (2.5)$$

ESA da görüntü işleme de piksel değer aralığının 0-255 olması gerektiğinden görüntülerdeki negatif yani siyah değerlerden kurtulmak için bir ReLU aktivasyon fonksiyonundan geçirilir [56]. Bu aşamada daha önce de kullanılan doğrusal olmayan sigmoid ve tahn fonksiyonlarının yerine daha bazı çalışmalar aksini söylese de hızlı sonuç üreten ReLU fonksiyonu kullanılır [57-59].






Şekil 2.6 ReLU fonksiyonu.

Böylece ReLU aktivasyon fonksiyonu, negatif değerleri 0 yaparken diğer değerleri sabit kalacak şekilde düzenler, Denklem (2.6) [60];

$$f(x)=\max(0,x) \quad (2.6)$$

### 2.2.2. Havuzlama katmanı

Filtreleme işlemlerinden sonra hesaplama karmaşıklığını azaltmak için havuzlama işlemi yapılır. Bu işlemde görüntünün enine ve boyuna piksel değerleri azaltılır. Bu işlemde genelde maksimum havuzlama, ortalama havuzlama ve L2-norm havuzlama gibi yöntemler kullanılmaktadır [56]. Şekil 2.7’de bu durum gösterilmektedir.



Şekil 2.7 Özellik matrisinin 2x2 havuzlama filtresinin uygulanması.

### 2.2.3. Düzleştirme

YSA'dan önceki son aşama pürüzsüzleştirme (düzleştirmede), sırayla bir veya birkaç evrişim ve havuzlama sürecinin sonunda matris biçiminde elde edilen son görüntü vektör haline dönüştürülür. Vektördeki her bir satır YSA'da öznelik olarak ele alınarak bir girişi oluşturur [54].

### 2.2.4. Tam bağlantı katmanı

Bu aşamada özellikleri çıkarılmış saf bir veri YSA'ya işlenir ve nihai sınıflandırma burada gerçekleşir. ESA ilk başarılı uygulaması olan LeNet'te, bu katman sadece 30 birimden oluşmaktadır. Her bir birim kendinden sonraki katmandaki birime bağlıdır. Bu katmanda kendinden önceki katmanla yaklaşık 6000 bağlantıya sahip iken, sınıflandırma yapacak çıkış katmanı ile de yaklaşık 300 bağlantıya sahiptir [61].

Bu katmanda ezberlemeyi azaltmak için gizli katmanlar arasında veri seyreltilmesi için normalleştirme "dropout" yöntemi kullanılır [62]. Bu yöntem etkisini ImageNet yarışmasında getirdiği sonuçlarla kanıtlamıştır [28, 63].

## 2.3. Derin Öğrenme Modelleri

Derin öğrenme mimarisinin Denklem (2.7)'de birçok yaygın uygulaması mevcuttur [55].

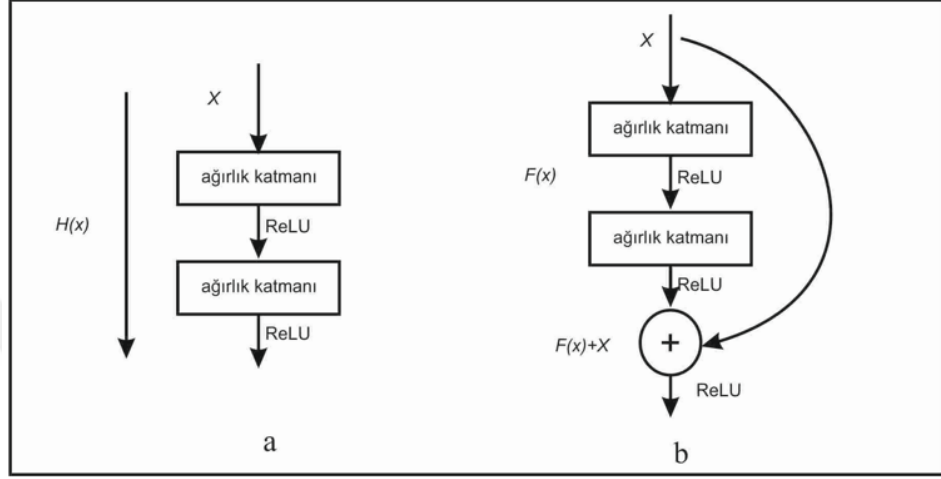
$$\text{Ham Data} \rightarrow \text{Evrişim} \times n \rightarrow \text{Düzleştirme} \rightarrow \text{YSA} \rightarrow \text{Sınıflandırma} \quad (2.7)$$

ResNet, U-Net, YOLOv3, Mask R-CNN bu modellerin en çok kullanılanları olup alt bölümlerde daha ayrıntılı incelenecektir.

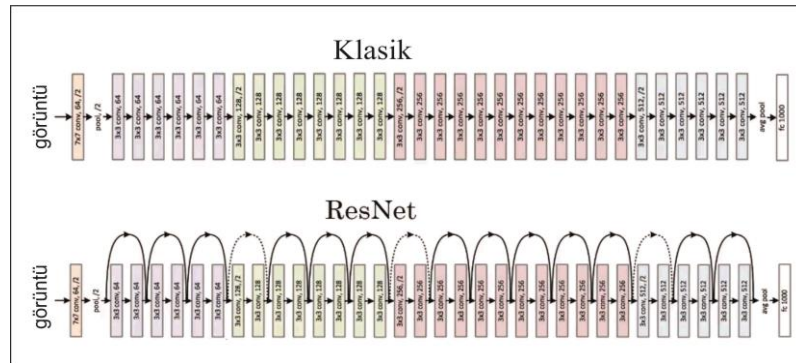
### 2.3.1. Resnet

Derin öğrenme modellerinde eğitim zorlu bir süreçtir [64]. Veri kaybın uğramadan daha derin katmanlar oluşturarak doğruluk oranını arttırmak arzu edilen bir durumdur. ResNet mimarisi bu süreci kolaylaştırmak, hızlandırmak ve evrişim katmanını arttırarak daha derin bir ağ kurmayı amaçlamaktadır [65].

ResNet-152 (152 katmanlı ResNet) mimarisini oluşturan Microsoft Asya Araştırma Lab. (Microsoft Research Lab. Asia-MSRA) ekibi %3.57'lik bir hata oranı ile ILSVRC & COCO 2015 yarışmasının birincisi olmuştur [66]. Microsoft ekibi, ağı derinleştirirken ölü nöron, parametre artması, gibi problemlere çözüm bularak ve daha az parametre kullanarak daha derin ağlar oluşturmayı başarmıştır [65].




Şekil 2.8 klasik ESA ve ResNet bloğu karşılaştırılmıştır. ResNet 'in temelde yaptığı iş; giriş  $X$  katmanına uygulanan evrişim sonucunda oluşan veriye  $F(x)$  giriş katmanını da ekleyerek  $F(x)+X$ , daha önceki katmanların bilgisini daha ileri katmanlara öznitelikleri açısından daha güçlü halde iletmeyi sağlamaktır. Böylelikle ağı eğitimi kolaylaştırılmış ve model başarımı arttırılmıştır. Şekil 2.9'da giriş bilgisi katmanlardan geçerek tam bağlı katmana kadar gelen süreç hem klasik hem de ResNet ağı için görselleştirilmiştir.



### 2.3.2. U-net

U-Net mimarisi daha çok ilk başlarda medikal görüntüleri üzerinde muadillerinden farklı olarak eğitim için daha az veri kullanarak bölütleme işlemi yapar [67].



Şekil 2.10 U-Net mimarisi.

U-Net modeli Şekil 2.10 da görüldüğü gibi iki kısımdan oluşmaktadır. İlk kısımda evrişim ve havuzlama katmanları ile boyut küçültülerek ilerler. İkinci kısımda evrişim ve havuzlama ile boyut büyütülerek çıktı görüntüsünün çözünürlüğü artırılır. Bu mimaride YSA bulunmaz, ayrıştırılan niteliklerle çıktı görüntü birleştirilerek sonuca erişilir.

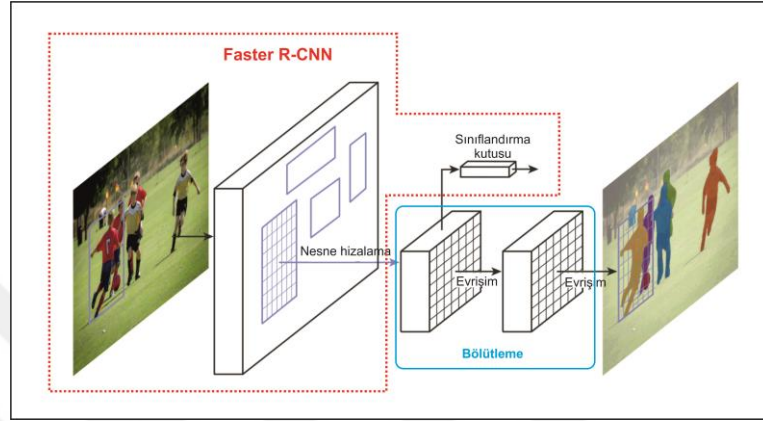
Elektron mikroskobu (EM) görüntüleri üzerinden, bölütleme yapılan bir yarışmanın [68] veri seti üzerinden, NVidia Titan ekran kartı (6GB) ile 30 adet görselle 10 saatlik bir eğitim sonucunda, en az eğrilik hatası puanı ile en iyi başarıyı elde etmiştir [69].

Tablo 2.2 Elektron Mikroskobu Bölütleme Yarışması sonuçları [69].

Sıra	Grup Adı	Eğrilik Hatası	Ölçek Hatası	Piksel Hatası
1	U-Net	0,000353	0,0382	0,0010
2	DIVE-SCI	0,000355	0,0305	0,0611
3	IDSIA	0,000420	0,0504	0,0584
4	DIVE	0,000430	0,0545	0,0582
...				
10	IDSIA-SCI	0,000653	0,0189	0,1027

### 2.3.3. Mask r-cnn

Maskelenmiş bölgesel evrişimsel ağ (Mask R-CNN) mimarisi Facebook yapay zekâ ekibi tarafından Faster R-CNN üzerine inşa edilmiş bir derin öğrenme modelidir. Görüntü üzerinde nesne tanıma, konum bulma ve bölütleme için geliştirilmiştir [70].



Şekil 2.11 Mask R-CNN mimarisi [70].

Şekil 2.11’de Mask R-CNN mimarisinin ilk katmanı bir ESA’dır. Bu katmanda görüntü özellikleri çıkartılarak, görüntü üzerinde var olan nesnelerin sınıflandırması yapılır ve konumlarını bulunur. İkinci kısımda ise bulunan nesnelere sınıflandırmasının yapılması için evrişim katmanlarından geçirilir ve maskelenmiş çıkış görüntüsü elde edilmiş olur. Şekil 2.12’de Mask R-CNN’in ilk aşaması ve sonrasında maskelenmiş son görüntüsü yer almaktadır. Şekilden uçak için 0,945 ve personeller için de en az 0,90 oranından tahmin ettiği gözükmektedir.



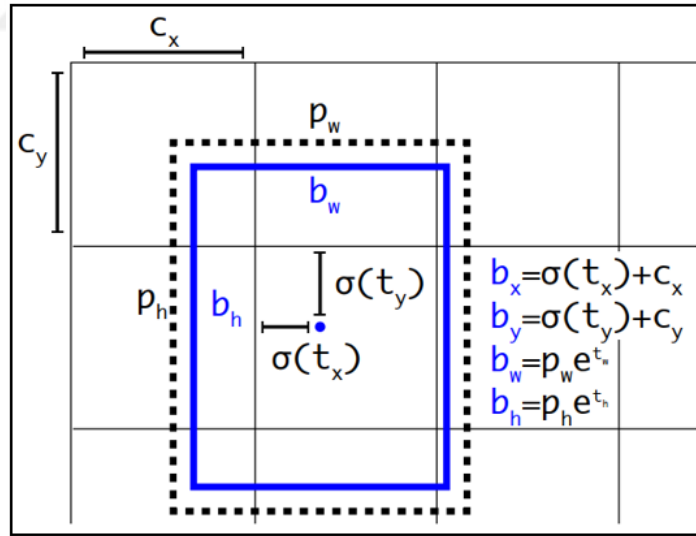
Şekil 2.12 Mask R-CNN in ilk aşaması maskelenmiş son görüntü [71].

### 2.3.4. Yolov3

Nesne tespiti ve takibi için sınıflandırma temelli algoritmalarda model resim üzerinde birden fazla konum ve ölçekte uygulanır ve resimdeki yüksek skorlu bölgeler seçici arama metoduyla tespit edilir. YOLOv3'te ise özetle tüm resme tek bir nöral ağ uygulanır, bu nöral ağ ile resim bölgelere ayrılır ve her sınırlayıcı kutu (bounding box) ile bölgenin olasılığı tahmin edilir. Tahmin edilen olasılıklar, modelde sınır kutularının ağırlığı olarak ele alınır [72].

YOLOv3'ün sınıflandırma temelli sistemlere göre avantajlarından bazıları aşağıda sunulmuştur [73] :

- Test süresince tüm resme bakıldığı için tahminler resmin genelinde güncellenir.
- R-CNN ve Faster R-CNN'de tek bir resim için binlerce nöral ağ değerlendirmesi gerekirken YOLOv3 de tek bir ağ değerlendirmesi ile tahminler yapılır.
- YOLOv3'te kullanılan Darknet; Mask R-CNN'de kullanılan ResNet152'den daha hızlı çalışır ve gerçek zamanlı uygulamalar için idealdir.



Şekil 2.13 Sınırlayıcı kutu konum tahmini [73].

YOLOv3'te ağ her sınırlayıcı kutu için boyut kümeleri olarak sınırlayıcı kutu şeklinde 4 koordinat tahmin edilir. Bu koordinatlar sırasıyla nesnenin orta noktasının x koordinatı ( $B_x$ ), nesnenin orta noktasının y koordinatı ( $B_y$ ), nesnenin genişliği


(Bw) ve nesnenin yüksekliğidir (Bh). Her bir sınırlayıcı kutuda nesne tahminleri için lojistik regresyon yöntemi kullanılır [73].

Her kutu, çoklu etiket sınıflandırması (multi-label classification) kullanarak sınırlayıcı kutunun içerebileceği sınıfları tahmin eder. Bu işlem için softmax transfer fonksiyonu yerine bağımsız lojistik sınıflandırıcılar kullanılır. YOLOv3'te eğitim sırasında her bir etiket için sınıflandırma kaybını (classification loss) hesaplarken ortalama karesel hata (mean squared error) yerine ikili çapraz-entropi kaybı (binary cross-entropy loss) kullanılır [73]. İkili çapraz-entropi kaybı, tahminin gerçek değerden ne kadar uzakta olduğunun hesaplanması için kullanılan bir yitim fonksiyon yöntemidir.

Tablo 2.3 Mimarilerin başarılarının Karşılaştırılması [73].

	Mimari	AP	AP <sub>50</sub>	AP <sub>75</sub>	AP <sub>S</sub>	AP <sub>M</sub>	AP <sub>L</sub>
Faster R-CNN w TDM	Inception-ResNet-v2-TDM	36.8	57.7	39.2	16.	39.8	52.1
YOLOv2	DarkNet-19	21.6	44.0	19.2	5.0	22.4	35.5
RetinaNet	ResNet-101-FPN	39.1	59.1	42.3	21.8	42.7	50.2
RetinaNet	ResNeXt-101-FPN	40.8	61.1	44.1	24.1	44.2	51.2
YOLOv3 608x608	Darknet-53	33.0	57.9	34.4	18.3	35.4	41.9

YOLOv3'ün saniye başına düşen kare sayısı (Frame Per Second - FPS) başarımı diğer modellerden iyi olmasına rağmen, Şekil 2.14'de görüldüğü üzere ResNet-152 kullanan FPN Faster R-CNN'nin başarımı daha iyidir [73].



Şekil 2.14 Mimarilerin başarılarının COCO mAP<sub>50</sub> veri Kümesi üzerinden karşılaştırılması [73].

## 2.4. Değerlendirme Metrikleri

Oluşturulan modellerin sonuçlarının belirlenmesi ve karşılaştırılabilmesi için metrikler önemli rol oynamaktadır. Bu çalışmada oluşturulan modellerin sonuçlarının başarımını ölçmek için kullanılan hesaplama yöntemleri alt başlıklar şeklinde verilmiştir.

### 2.4.1. Karışıklık matrisi

Karışıklık matrisi, eğitilmiş modelin sınıflandırma performansını ölçmek için kullanılan bir araçtır. Bu matristeki her bir veri diğer ölçüm metrikleri tarafından kullanılır.

Tablo 2.4 Karışıklık Matrisi.

Gerçek Durum			
<i>DOĞRU</i>	<i>YANLIŞ</i>		
Doğru Pozitif	Yanlış Pozitif	<i>DOĞRU</i>	Tahmini Durum
Yanlış Negatif	Doğru Negatif	<i>YANLIŞ</i>	

- Doğru Pozitif (TP) : Gerçek değer “Doğru” olduğu ve model tahmin değerlerinin de “Doğru” olduğu sonuçların sayısı.
- Doğru Negatif (TN) : Gerçek değer “Yanlış” olduğu ve model tahmin değerlerinin de “Yanlış” olduğu sonuçların sayısı.
- Yanlış Pozitif (FP) : Gerçek değer “Yanlış” olduğu ve model tahmin değerlerinin ise “Doğru” olduğu sonuçların sayısı.
- Yanlış Negatif (FN) : Gerçek değer “Doğru” olduğu ve model tahmin değerlerinin ise “Yanlış” olduğu sonuçların sayısı.

### 2.4.2. Doğruluk değeri

Yapılan ölçümlerin TP+TN olarak ifade edilen isabetli tahminlerin sayısının toplam tahmin sayısına bölümü olarak Denklem (2.8)’deki gibi hesaplanır. Yapılan ölçümün gerçek ölçümlere ne kadar yakın olduğunu gösterir [74].



$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.8)$$

### 2.4.3. Kesinlik değeri

Yapılan ölçümlerin TP olarak ifade edilen gerçekte “Doğru” olan değerlerin sayısının, tahminlerin, TP+FP “Doğru” olarak sonuç veren tahminlerin sayısına oranı olarak Denklem (2.9)’daki gibi hesaplanır. “Doğru” olarak tahmin edilen ölçümlerin, gerçekte “Doğru” olan değerlere ne kadar yakın olduğunu gösterir [74].

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2.9)$$

### 2.4.4. Duyarlılık değeri

Yapılan ölçümlerin TP olarak ifade edilen gerçekte “Doğru” olan değerlerin sayısının, tahminlerin, TP+FN gerçekte “Doğru” değerlerin sayısına oranı olarak Denklem (2.10)’deki gibi hesaplanır [74]. “Doğru” olarak tahmin edilen ölçümlerin, gerçek de “Doğru” olan değerlere ne kadar yakın olduğunu, yani gerçekte ulaşılması gereken bilgilere ne oranda ulaşıldığını gösterir [75].

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2.10)$$

### 2.4.5. F1-ölçümü değeri


F1-Ölçümü hesaplanırken Duyarlılık ve Kesinlik değerlerinin harmonik ortalaması alınır [74]. Yapılan tahminlerin gerçek değerler ile ne kadar uyduğuna dair göstergedir [75].

$$F1\text{-Ölçütü} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2.12)$$

#### 2.4.6. AP ve map değeri

AP (Average Precision - Ortalama hassasiyet) değeri, Kesinlik-Duyarlılık grafiğinin altında kalan alanın her sınıf için ayrı ayrı hesaplanması Denklem 2.13 te sunulmaktadır.

$$AP = \int_0^1 p(r) dr \quad (2.13)$$



Şekil 2.15 Kesinlik – Hassasiyet grafiği.

Ortalama hassasiyetlerin ortalaması (Mean Average Precision–mAP) değeri, her sınıf için hesaplanan AP değerlerinin aritmetik ortalanması alınarak Denklem (2.14)'de sunulmaktadır [76].

$$mAP = \frac{1}{N} \sum_{\rho=1}^N AP(\rho) \quad (2.14)$$

#### 2.4.7. Cohen kappa değeri

Gerçek değerlerin ve tahmin sonuçlarının uyuşmalarını ölçen istatistiksel bir yöntemdir. Cohen kappa ölçüsü, sonuçlardaki uyuşmaların şans eseri olabileceğini de

ele aldığı için basit yüzde oranı olarak hesaplayan metriklerden daha güçlü bir sonuç verdiği kabul edilir [77]. Denklem (2.15)'teki hesaplanan.  $\kappa$  değerinin 1'e yaklaşması performansın arttığının göstergesidir [17].

$$\kappa = \frac{\text{Pr}(a) - \text{Pr}(e)}{1 - \text{Pr}(e)} \quad (2.15)$$

$\text{Pr}(a)$  değeri, tahmin ve gerçek cevapların uyuşma sayılarının  $\text{TP} + \text{TN}$ , toplam sayıya bölünmesiyle Denklem (2.17)'de sunulmaktadır.

$$N = \text{TP} + \text{TN} + \text{FP} + \text{FN} \quad (2.16)$$

$$\text{Pr}(a) = \frac{\text{TP} + \text{TN}}{N} \quad (2.17)$$

$\text{Pr}(e)$  değerinin, yani uyuşmanın şans eseri ortaya çıkma olasılığının hesaplanması biraz daha zahmetlidir. İlk olarak tahmin değerlerindeki “Doğru” cevapların sayısının tüm tahminlere oranı Denklem (2.18) ile gerçek değerlerdeki “Doğru” değerlerinin sayısının tüm değerlerin sayısına oranı Denklem (2.19) olarak sunulmaktadır.

$$d_1 = \frac{\text{TP} + \text{FP}}{N} \quad (2.18)$$

$$d_2 = \frac{\text{TP} + \text{FN}}{N} \quad (2.19)$$

$$d = d_1 \times d_2 \quad (2.20)$$

Bulunan bu sonuçlar çarpılarak  $d$  değeri Denklem (2.20) elde edilir. Sonraki adımda, tahmin değerlerindeki “Yanlış” cevapların sayısının tüm tahminler oranı Denklem

(2.21) ile gerek deęerlerdeki ‘‘Yanlıř’’ deęerlerinin sayısının tm deęerlerin sayısına oranını Denklem (2.22) olarak sunulmaktadır.

$$y_1 = \frac{FN+TN}{N} \quad (2.21)$$

$$y_2 = \frac{FN+TP}{N} \quad (2.22)$$

$$y = y_1 \times y_2 \quad (2.23)$$

Bulunan Denklem (2.20)’de bulunan  $d$  ve Denklem (2.23)’de bulunan  $y$  deęerleri toplanarak  $\text{Pr}(e)$  deęeri Denklem (2.24)’de;

$$\text{Pr}(e) = d + y \quad (2.24)$$

bulunmuř olur.

### 3. MATERYAL

#### 3.1. Kullanılan Veri Kümleri


Bu çalışmada, derin öğrenme modellerinin eğitimi ve doğrulaması (validasyonu) için MURA ve EDD2020 veri kümeleri kullanılmıştır.

##### 3.1.1. Mura

Kas-iskelet radyografilerde aykırılık tespiti için yeterince büyük veri kümesi olan MURA veri seti Stanford Üniversitesi Makine Öğrenmesi grubu tarafından oluşturulmuştur [12]. Veri Setinde 14,863 çalışma içerisinde 40,561 X-RAY görüntüsü içermektedir. Veri setindeki her görüntü elle etiketlenmiştir. Ekip aynı zamanda kendilerinin geliştirdiği 169-katmanlı DenseNet ile AUROC için 0,929, hassasiyet için 0,815 ve kesinlik için 0,887 başarımlar elde etmişlerdir [12]. Tablo 3.1’de MURA veri kümelerinin farklı çalışmalara ait görüntülerin eğitim ve doğrulama veri adetleri yer almaktadır. Ayrıca Şekil 3.1’de ise MURA veri setinden farklı uzuvlar için örnek görüntüler verilmiştir.

Tablo 3.1 MURA veri seti içeriği.


Çalışma	Eğitim		Doğrulama		Toplam
	Normal	Aykırı	Normal	Aykırı	
Dirsek	1094	660	92	66	1912
Parmak	1280	655	92	83	2110
El	1497	521	101	66	2185
Pazu Kemiği	321	271	68	67	727
Ön Kol	590	287	69	64	1010
Omuz	1364	1457	99	95	3015
Bilek	2134	1326	140	97	3697
Toplam Çalışma	8280	5177	661	538	14656



Şekil 3.1 MURA veri setinden seçilmiş görüntüler.

### 3.1.2. Edd2020

Endoskopi görüntülerinde teşhis koyma ve bölütleme 2020 (Endoscopy Disease Detection and Segmentation - EDD2020) yarışmasında kullanılmak üzere 512×512 boyutlarında 5 ayrı sınıfta olmak üzere toplamda 386 görsel bulunmaktadır [78]. Görüntüler 5 ayrı merkezde birden fazla popülasyonu hedefleyen farklı hastalıklı bölgelerden oluşmaktadır. Tüm görüntüler tıp uzmanları ve deneyimli doktora sonrası araştırmacılar tarafından etiketlenmiştir.



Şekil 3.2 EDD2020 veri setinden seçilmiş görseller.

## **3.2. Kullanılan Materyal**

### **3.2.1. Donanım**

Tez çalışması kapsamında, aşağıdaki donanım özelliklerine sahip bir bilgisayar kullanılmıştır.

- İşlemci: Intel i7-3770
- Ekran Kartı: GTX 1050 Ti 4GB
- Bellek: 16 GB
- Sabit Disk: 256 SSD

### **3.2.2. Yazılım**

Bu çalışma, Spyder ortamında Python dili kullanılarak gerçekleştirilmiştir. Ayrıca çalışmamızda, makine öğrenmesi algoritmalarının GPU üzeri çalışabilmesini sağlayan cuDNN [79] destekli, U-Net, Mask R-CNN, ResNet algoritmaları için TensorFlow [80] ve YOLOv3 kullanımı için de DarkNet [72] kütüphaneleri kullanılmıştır.


## 4. YÖNTEM VE BULGULAR

Bu bölümde tez çalışmasında kullanılan yöntemler ve bu yöntemlerin uygulanması sonucunda elde edilen bulgular sunulmuştur.

### 4.1. Humerus Ön Kol Kemiğinde Anomali Tespiti

MURA veri serinde bulunan 7 ayrı sınıf içerisinde Humerus (kol kemiği) verisine ait 727 ayrı çalışmadan 1273'ü eğitim 1272'si ise doğrulama olmak üzere toplam 2545 X-RAY Röntgen görüntüsü kullanılmıştır [12].

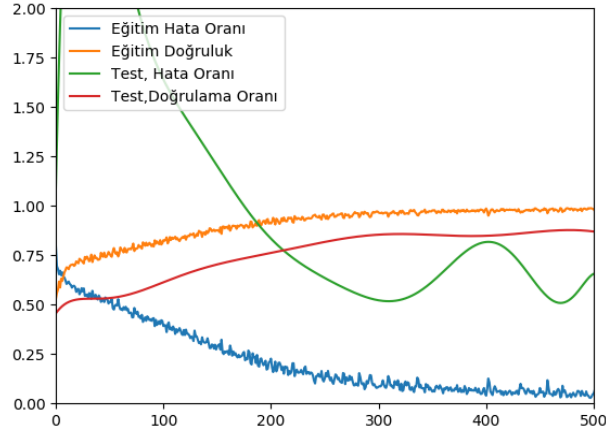
Bu çalışmada, görüntüler  $128 \times 128 \times 3$  (Genişlik  $\times$  Yükseklik  $\times$  Kanal Sayısı) olarak yeniden boylandırılarak kullanılmıştır. Geliştirilen birçok ESA içerisinde en iyi performansa ResNet bloklarıyla harmanlanan melez (hibrit) ESA yapısı sahiptir. Şekil 4.1'de önerilen ESA mimarisi görülmektedir.



Şekil 4.1 Önerilen ESA'nın mimarisi

Önerilen ESA mimarisi önde 2 adet evrişim katmanına, sonra 12 adet Resnet bloğuna, ardından da 256 giriş birimine ve 2 çıkış birimine sahip tam bağlı bir YSA'ya giriş yapar. Eğitim süresince oluşabilecek ezberlemeyi engellemek için %50 unutmaya (dropout) uygulanmıştır. Son adımda ise 2 birimli Çıkış katmanında softmax aktivasyon fonksiyonu kullanılarak ikili (binary) sınıflandırma işlemi gerçekleştirilir. ESA sahip olduğu toplamda 965.890 parametrenin 962.818 tanesi eğitilebilirdir.





Şekil 4.2 Model eğitim sonuç grafiği.

Şekil 4.2’de önerilen modeli eğitim sonuç grafiği görülmektedir. ESA 64 birimlik paketler (Batch) halinde 500 adımda eğitilmiştir. Eğitim yitim değeri kategorik çapraz-entropi kaybı (categorical cross-entropy loss) hesabına göre 0,0990 ve eğitim doğruluk oranı ise 0,9638 olarak hesaplanmıştır. Test amaçlı onay yitim değeri kategorik çapraz-entropi kaybı hesabına göre 0,1154 ile doğruluk oranı 0,9568’de kalmıştır. Şekil 4.3’te de test amaçlı kullanılan veri setine ait rastgele seçilmiş 20 adet X-RAY görüntüsü yer almaktadır.



Şekil 4.3 Test için tutulan veri setinde rastgele seçilmiş 20 adet X-RAY görüntüsünü sınıflandırılması.

#### 4.1.1. Humerus pazu kemiğinde anomali tespiti sonuçları

Geliştirilen bu çalışmada Resnet yöntemi kullanılarak elde edilen sonuç değerleri, Cohen Kappa [17] metriği kullanılarak radyoloji uzman gruplarını ve Stanford Üniversitesi makine öğrenmesi ekibinin geliştirdiği 169 katmanlı DenseNet ESA'nın [12] sonuç değerleri ile karşılaştırılmıştır. Tablo 4.1'de görülen karşılaştırma sonucunda bu tez çalışmasında önerilen ResNet üzerine inşa edilmiş yöntem ile uzman radyologlardan ve DenseNet'ten daha yüksek başarımlar elde edilmiştir.

Tablo 4.1 MURA veri seti başarımlarını karşılaştırması.

	Radyoloji Uzm Grup -1	Radyoloji Uzm Grup -2	Radyoloji Uzm Grup -3	DesNet	ResNet
Pazu Kemiği	0,867	0,733	0,933	0,600	0,9568

MURA veri setinde sadece pazu kemiği için geliştirmiş olduğumuz model diğer sınıflara da uygulanınca Tablo 4.2'deki sonuçlara ulaşıldı.

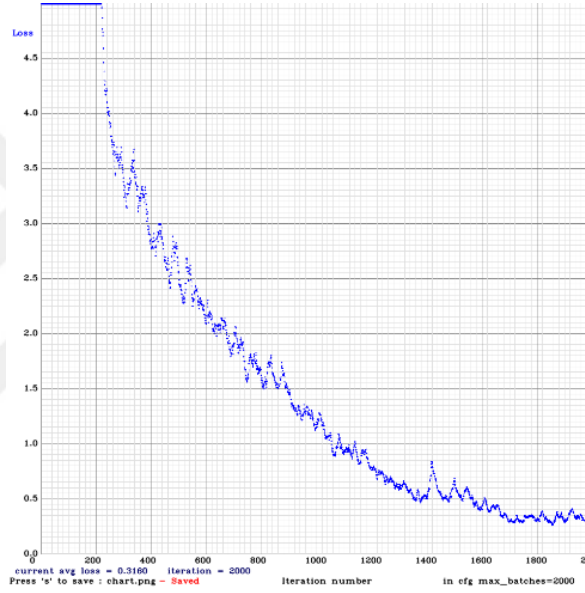
Tablo 4.2 MURA veri seti başarımlarını karşılaştırması.

	Radyoloji Uzm Grup -1	Radyoloji Uzm Grup -2	Radyoloji Uzm Grup -3	DesNet	Çalışmamız
Dirsek	0,850	0,710	0,719	0,710	0,595
Parmak	0,304	0,403	0,410	0,389	0,487
Ön Kol	0,769	0,802	0,798	0,737	0,348
El	0,661	0,927	0,789	0,851	0,384
Pazu Kemiği	0,867	0,733	0,933	0,600	0,956
Omuz	0,864	0,791	0,864	0,729	0,407
Bilek	0,791	0,931	0,931	0,931	0,627
Ortalama	0,731	0,763	0,778	0,705	0,543

#### 4.2. Endoskopi Görüntülerinde Anomali Tespiti

Bir diğer veri seti de EDD2020 endoskopi görüntülerindeki 386 adet görüntünün 90 adedi test, geri kalan 296 adedi de eğitim için kullanılmıştır [78]. Anomali tespit ve görüntü üzerindeki konumlandırılması YOLOv3 mimarisi görüntü üzerindeki nesnelerin tespitinde hız üstünlüğü nedeniyle tercih edilmiştir.

Konfigürasyon yapılırken, görüntüler  $256 \times 256 \times 3$  (Genişlik  $\times$  Yükseklik  $\times$  Kanal Sayısı) olarak yeniden boyutlandırılmıştır. Boyutlandırılmış veri 70 adet evrişim katmanından geçirilip özellik haritaları çıkarılarak havuzlanmış ve YSA'dan geçirilerek softmax aktivasyon fonksiyonu ile sınıflandırması yapılmıştır. ESA'nın eğitimi GPU sınırlamalarından dolayı 2'li paketler halinde 2000 iterasyonda gerçekleştirilmiştir. Şekil 4,4'te YOLOv3 modelinin eğitim sonucu görülmektedir. Eğitim sonucu Ortalama Karesel Hata Oranı 0,316 ve mAP50=0,370 olarak hesaplanmıştır. Doğruluk 0,85 oranında başarıma erişirken hassasiyet 0,31'de kalmıştır. Tüm sınıflara ait doğruluk oranları Tablo 4.3'de gösterilmiştir.



Şekil 4.4 YOLOv3 Model eğitim sonuç grafiği.

Tablo 4.3 EDD2020 veri setinin, YOLOv3 mimarisi kullanılarak yapılan eğitimin test sonuçları.

Sınıf	AP	TP	FP
BE	0,5273	27	2
Suspicious	0,2579	5	1
HGD	0,3579	9	3
Cancer	0,3895	4	0
Polyp	0,3197	8	3
F1-Score= 0,46	Kesinlik= 0,85	mAP= 0,37	Duyarlılık= 0,31

#### 4.2.1. Endoskopi görüntülerinde anomali tespiti sonuçları


Bu tez çalışmasında EDD2020’de kullanılan veri setinde gerçek zamanlı endoskopi görüntülerinin kestirimi için YOLOv3 mimarisi kullanıldı. Gerçek zamanlı çalışma için 25 FPS’e kadar çıkabilen bir sonuca erişilse de modelin eriştiği başarımlar Tablo 4.4’te görüldüğü gibi daha düşük kalmıştır.

Tablo 4.4 YOLOv3 EDD2020 veri seti eğitim sonuçları.

Sınıf	AP
BE	0,52
Suspicious	0,25
HDG	0,35
Cancer	0,38
Polyp	0,31
mAP	0,36

#### 4.3. Endoskopi Görüntülerinde Bölütleme


EDD2020 veri setindeki endoskopi görüntülerinde tam otomatik olarak bölütleme tespiti için U-net ve Mask R-CNN derin öğrenme mimarileri kullanılmıştır. Eğitimlerde EDD2020 veri setine ait olan 386 görüntünün 90’ı test, geri kalan 296 adedi ise ESA eğitimi için kullanılmıştır. ESA eğitiminde kullanılan görüntülerden rastgele seçilen 7 görsel ve bunlara ait uzmanlar tarafından etiketlenmiş 7 adet referans etiket görüntüsü Şekil 4.5’te görülmektedir.



Şekil 4.5 EDD2020 veri setinden rastgele seçilmiş 7 görüntü ve maske referansı.

### 4.3.1. U-net kullanılarak yapılan uygulama

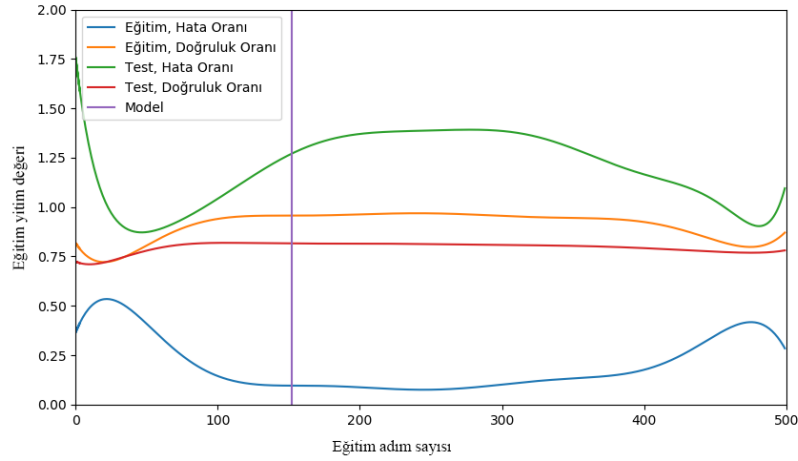
Eđitim için kullanılacak olan goruntuler 128×128 olarak yeniden boyutlandırılıp RGB olarak yuklenmiřtir.



řekil 4.6 Gerek Referans Deđer Goruntusu (a) Normal Goruntu, (b) Etiketli goruntu, (c) Etiket goruntusu.

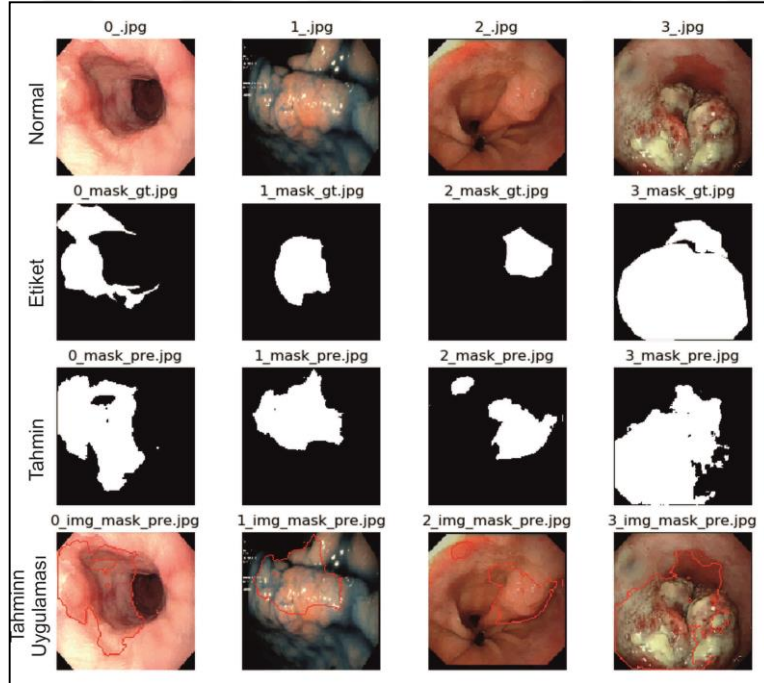
Eđitim verileri hazırlandıktan sonra omurga olarak U-Net mimarisi kullanan bir ESA oluřturulmuřtur. Oluřturulan ESA, U-Net mimarisine uygun olarak iki kısımdan oluřmaktadır. İlk kısmı 4 bloktan oluřup her blok 2 evriřim katmanı ve havuzlamadan oluřmaktadır. Bu kısımdan sonra bir dar bođaz oluřur ve bu bođazda da 2 evriřim katmanı bulunmaktadır. Mimarinin ikinci kısmında ise ilk kısımdaki gibi 4 bloktan ve her blokta 2 evriřim katmanından oluřmaktadır. U-Net mimarisinin ıkıřı evriřim katmanı ise 0 ile 1 aralıđında deđer ureten sigmoid aktivasyon fonksiyonuna sahiptir. Boylice modelimizde 16 evriřim katmanı ve toplamda 1.962.625 parametre bulunmaktadır. Modelin eđitimi 16'lık paketler halinde 500 adımda gerekleřmesine rađmen 152. adımda en iyi deđerlere sahip model kullanılmıřtır. řekil 4.7'de U-Net mimarisinin eđitim ve test sonu grafiđi gorlmektedir. Bu sonulara gore 152 adımdan sonra model ezberlemeye gemiřtir. Bu nedenden dolayı 152. adımdan sonra eđitim ve test sonuları arasında uyuřmazlık gorlmüřtur.

U-Net modelinin eđitime ait yitim deđerleri ikili apraz-entropi kaybı hesabına gore 0,143; dođrulama bařarısı ise 0,96 olarak hesaplanmıřtır. Buna karřın test verisine ait yitim deđerleri ikili apraz-entropi kaybı hesabına gore 0,99; test dođruluk bařarımı 0,83 olarak hesaplanmıřtır.



Şekil 4.7 Model Eğitim Sonuç Grafiği.

Şekil 4.8'de U-Net modeline ait test verilerinden rastgele seçilmiş görüntüler ve bölütleme uygulamasının sonuçları görülmektedir. Bazı görüntülerde, maskeleye yapılması gereken anomali bölgelerinin tamamını bölütlememiş olsa bile, anomali içeren tüm görüntülerde anomali bölgelerinin büyük bir kısmı tespit edilmiş ve AP 0,83 lük bir başarımla kazanarak tatmin edici bir performans ortaya koymuştur.

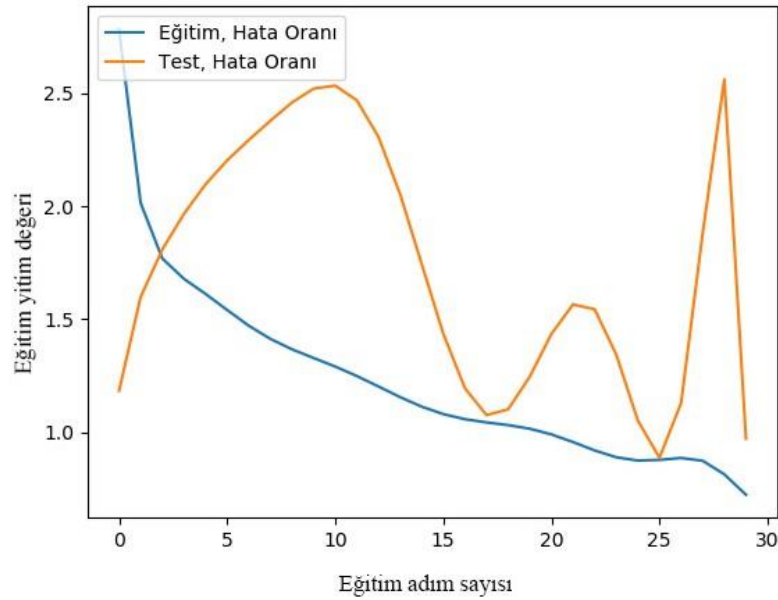


Şekil 4.8 U-Net modelinin test verilerinden rastgele seçilmiş görüntüler ve bölütleme uygulaması.

### 4.3.2. Mask r-cnn kullanılarak yapılan uygulama

EDD2020 veri setindeki etiket verilerini Mask R-CNN mimarisinde kullanabilmek için verilen “.tif” uzantılı etiket dosyaları ikili (binary) dosya formatına dönüştürülmüştür. Binary formattaki beyaz yani piksel değeri 1 olan veri kümelerinin kenar sezimlemesi sonucunda çevre hattı çıkartılarak konumları elde edilmiştir. Tüm veriler için yapılan bu işlem sonucu “json” formatında olarak kaydedilmiştir. Yapılan bu ön işlemle ESA’da eğitilecek olan veri seti hazırlanmıştır. Eğitilecek görüntüler 1024×1024 şeklinde yeniden boyutlandırılarak RGB formatında eğitim etiketleri ise json formatındaki dosyadan okunarak ağa yüklenmiştir.

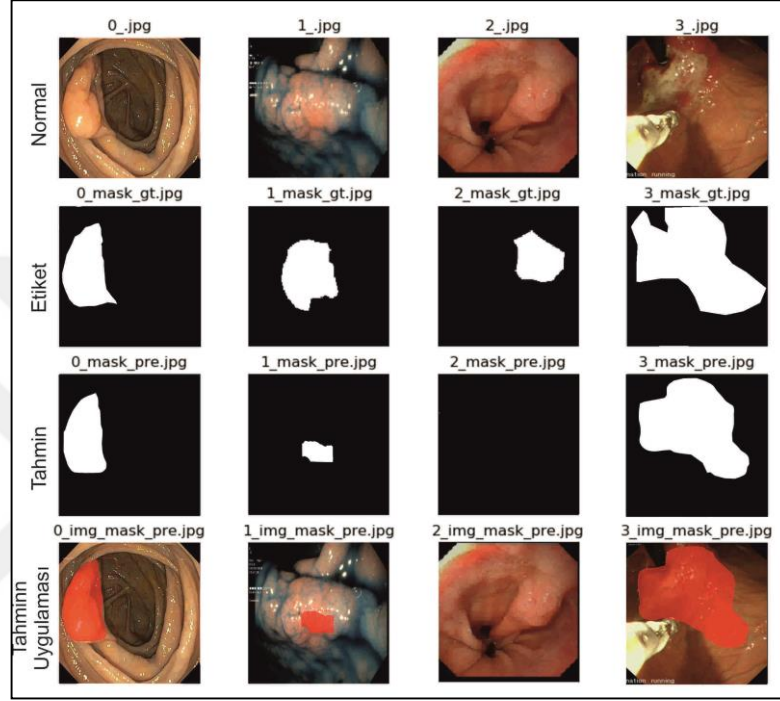
Mask R-CNN mimarisi için omurga yapı olarak ResNet-101 daha az veri kaybı ile daha derin katmanlar kurabilme avantajından dolayı seçilmiştir. ESA’da tekli paketler halinde 30 epoch ve her epoch 100 adımda eğitilmiştir. Şekil 4.9’da Mask R-CNN modelinin eğitim sonuç grafiği görülmektedir. Eğitim yitim kaybı 0,7284 ve test yitim kaybı 0,1154’te kalmıştır. Eğitim sonucunda, test verilerinde doğru tahmin kestirimi 0,2, hassasiyet 0,6 ve mAP 0,2 başarımlarında kalmıştır.



Şekil 4.9 Model Eğitim Sonuç Grafiği.

Şekil 4.10’da Mask R-CNN modelinin test verilerinden rastgele seçilmiş görüntüler ve üzerindeki bölütleme uygulaması görülmektedir. Bazı görüntülerde, maskeleme

yapılması gereken anomali bölgelerinin bir kısmını bölütlenmiştir. Buna rağmen bazı anomalileri kaçırmış ve AP 0,2 lik bir başarımda kalmıştır. Tahmin sonuçları ve gerçek referans değerleri arasında bir uyumsuzluk gözlemlenmiştir. Bu uyumsuzluğun sebebi, eğitim verilerinin sayısının yetersiz olması olarak açıklanabilir.



Şekil 4.10 Mask R-CNN kullanılarak eğitilmiş modelin test verilerinden rastgele seçilmiş görüntüler üzerindeki bölütleme uygulaması.


### 4.3.3. Endoskopi görüntülerinde bölütleme sonuçları

Tablo 4.5 incelendiğinde; EDD2020 veri setinde bölütleme için kullanılan iki farklı yöntemden U-Net mimarisi Mask R-CNN mimarisinden daha iyi sonuç vermiştir.

Tablo 4.4 Mask R-CNN, U-Net sonuç karşılaştırması.

Mimari	Doğruluk
Mask R-CNN	0,20
U-Net	0,83





Şekil 4.11 U-Net Mask R-CNN tahmin karşılaştırılması a) Orijinal Görüntü b) Gerçek Referans Maske c)U-Net tahmini d)Mask R-CNN tahmini.

Şekil 4.11’de Mask R-CNN, U-Net modellerinin EDD2020 veri setinden rastgele seçilmiş bir görüntü üzerinde uygulanması görülmektedir. Şekilde a: Normal Görüntü b: Gerçek Referans Maskesi c: U-Net tahmin sonucu d: Mask R-CNN tahmin sonucu görülmektedir.

## 5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, Derin Öğrenme yöntemlerini kullanarak medikal görüntüler üzerinden tam otomatik olarak anomalilik tespiti yapılmıştır. Bu alanda yapılan birçok araştırmaya rağmen, görüntü üzerinde özellikle gerçek zamanlı uygulamalarda aşılması gereken birçok problem yeni çalışmalara kapı aralamaktadır. Tez kapsamında önerilen anomali tespiti işlemi radyologlar üzerinde biriken yükü azaltmak ve insan hatasını asgari orana indirmeyi hedeflemektedir.

Çalışmada MURA (Stanford X-RAY kemik görüntüsü veri seti) ve EDD2020 (Endoskopi Hastalığı Tespiti ve Bölütleme yarışması) veri seti olarak kullanılmıştır. Bu veri setleri üzerinden Tensorflow ve Darknet kütüphaneleri üzerinden Mask R-CNN, YOLOv3, ResNet ve U-Net mimarileri kullanılarak derin öğrenme modelleri eğitilmiştir.

Tez kapsamında medikal görüntüler için birden fazla geliştirilen yöntemler ile önceki çalışmaların sonuçları karşılaştırılmıştır. Humerus (pazu kemiği) kemiklerinin X-RAY görüntüleri üzerindeki anomalilerinin tespiti için tasarlanan 12 ResNet bloğuna sahip modelde, test verilerindeki anomali tahminleri Cohen Kappa metriği ile 0,9568 oranında başarımla elde etmiştir.

Tablo 4.1 ve Tablo 4.2’de sunulan sonuçlara göre, pazu kemiği için bu tez çalışmasında önerilen Resnet modeli en yüksek başarımla sahip olsa da, ön kol kemiği anomalisinin sınıflandırılması için aynı başarıyı elde edememiştir. Ancak parmak anomalisinde de diğer yöntemler düşük skorlar üretmiş olmasına karşın bu tez çalışmasında önerilen Resnet yine de en iyi skoru üretmiştir. Resnet modelinin diğer kemik türleri için yeniden mimarisinin düzenlenmesi gelecekte yapılacak çalışmalar için önerilmektedir. Özellikle Komite Makinaları (Committee Machines) ile birden fazla farklı mimarideki model paralel bir şekilde eğitilerek en iyi skorları üreten modelin seçiminin yapılması önerilmektedir.

YOLOv3 mimarisi ile EDD2020 veri kümesi üzerine eğitilmiş modelin F1-Doğruluk Ölçümü 0,46; ortalama hassasiyetin ortalaması mAP skoru ise 0,37 oranında kalmıştır. Endoskopi görüntülerinde anomali tespiti ve bölütleme için Mask R-CNN ve U-Net mimarileri kullanılarak iki ayrı model kullanılmıştır. Mask R-CNN’de oluşturulan modelin AP skoru 0,20; U-Net’te oluşturulan modelin AP skoru ise 0,83 oranındadır. Endoskopi görüntülerinde anomali tespitine ilişkin Tablo 4.3’te gösterilen eğitim sonuçları başarımının düşük olmasındaki sebep YOLOv3 mimarisini eğitim için daha büyük bir veri hacmine ihtiyaç duymasındadır. Veri hacminin artırılması ve daha yüksek CUDA çekirdeğine sahip bir GPU ile daha iyi sonuçlara erişilmesinin mümkün olacağı düşünülmektedir.

Endoskopi Görüntülerinde Bölütleme Sonuçlarına göre Tablo 4.5 incelendiğinde; EDD2020 veri setinde bölütleme için kullanılan U-Net mimarisi daha iyi sonuç vermiştir. Şekil 4.11’de U-Net yönetimi gerçek referans maskeye daha yakın bir bölgeyi tahmin etmektedir. EDD2020’ye ait sonuçlar bu tez çalışmasının yapıldığı sırada açıklanmadığı için aynı veri kümesine sahip başka çalışmalarla karşılaştırılmamıştır.

Gerçekleştirilen tüm yöntemler aslında Radyoloji Uzmanlarının yükünü azaltarak yol gösterici bir araç olarak önerilmektedir. Ayrıca radyoloji raporu hazırlanması noktasında da gerçek görüntü üzerinde hedefe yönelik işaretlemelerin yapılması ile Uzmanlara önemli katkılar sunacağı düşünülmektedir.

## KAYNAKLAR

- [1] Davenport T. H., İş Dünyasında Yapay Zekânın Durumu, Çeviri: Göktem L., Editör:Talay S., *Digital Dönüşüm Yapay Zeka, Harvard Business Review Press*, Optimist Basım, İstanbul, 7-18,2019.
- [2] Brynjolfsson E., McAfee A., Yapay Zekanın Vaat Ettikleri, Çeviri: Göktem L., Editör:Talay S., *Digital Dönüşüm Yapay Zeka, Harvard Business Review Press*, Optimist Basım, İstanbul, 19-56, 2019.
- [3] Martinho-Truswell E., Teknik Ekipte Olmayan Çalışanların Yapay Zeka Hakkına Yanıtlayabilmesi Gereken 3 Soru, Çeviri: Göktem L., Editör:Talay S., *Digital Dönüşüm Yapay Zeka, Harvard Business Review Press*, Optimist Basım, İstanbul, 107-118, 2019.
- [4] Domingos P., *Master Algoritma - Yapay Öğrenme Hayatımızı Nasıl Değiştirecek?* Çeviri: Göbekçin T., 2. Baskı, Paloma Yayınevi, İstanbul, 2015.
- [5] Eagleman D., Brandt A., *Yaratıcı Tür*, Çeviri: Tozar Z. A., 1. Baskı, Domingo, İstanbul 2019.
- [6] Ng A., İlk Yapay Zekâ Projenizi Nasıl Seçmelisiniz, Çeviri: Göktem L., Editör:Talay S., *Digital Dönüşüm Yapay Zeka, Harvard Business Review Press*, Optimist Basım, İstanbul, 127-141, 2019.
- [7] Yampolskiy R. V., Şirketinizin Algoritmaları Hata Yaparsa Neler Olur, Çeviri: Göktem L., Editör:Talay S., *Digital Dönüşüm Yapay Zeka, Harvard Business Review Press*, Optimist Basım, İstanbul, 141-155, 2019.
- [8] Wilson H. J., Daugherty P., İşbirliğine Dayalı Zekâ: İnsan ve Yapay Zeka Güçlerini Birleştiriyor ,Çeviri: Göktem L., Editör:Talay S., *Digital Dönüşüm Yapay Zeka, Harvard Business Review Press*, Optimist Basım, İstanbul, 169-208, 2019.
- [9] Gür Y.E. ve diğ., Yapay Zekâ Alanındaki Gelişmelerin İnsan Kaynakları Yönetimine Etkisi, *Fırat Üniversitesi İİBF Uluslararası İktisadi ve İdari Bilimler Dergisi*, 2019, 3(2), 137-159.
- [10] Altaf F. ve diğ, Going Deep in Medical Image Analysis: Concepts Methods, Challenges, and Future Directions, *IEEE Access*, DOI:10.1109/ACCESS.2019.2929365.
- [11] Medical Imaging with DL, <https://2020.midl.io/> (Ziyaret tarihi: 07/03/2020).

- [12] Rajpurkar P. R. ve diğ., MURA: Large Dataset for Abnormality Detection in Musculoskeletal Radiographs, *arXiv:1712.06957v4*, 2018.
- [13] O. Pelka ve diğ. Branding - Fusion of Meta Data and Musculoskeletal Radiographs for Multi-Modal Diagnostic Recognition, *IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, Seoul, Korea (South), 2019.
- [14] Singh ve diğ., Automatic Defect Classification and Localization of Mura Defects, *Presented at WinTechCon-2019, organized by IEEE CAS Bangalore Chapter, IEEE Bangalore Section, and IEEE WiE Council Bangalore*, 2019.
- [15] Xi P. Ve diğ., An integrated approach for medical abnormality detection using deep patch convolutional neural networks, *The Visual Computer*, DOI:10.1007/s00371-019-01775-7.
- [16] Can S., Medikal Görüntüler için Yeni Bir Bölütleme Algoritması ve Analiz uygulaması, Yüksek Lisans Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2018, 529765.
- [17] Cohen J., A Coefficient of Agreement for Nominal Scales, *Educational and Psychological Measurement*, 1960, **20**(1), 37-46.
- [18] Kerimi A., Mahmoudi I., Khadir M. T., Deep Convolutional Neural Networks Using U-Net for Automatic Brain Tumor Segmentation in Multimodal MRI Volumes, *Lecture Notes in Computer Science*, Springer, Cham, 37-48, 2019.
- [19] Oakden-Rayner L., Exploring Large-Scale Public Medical Image Datasets, *Academic Radiology*, 2019, **27**(1), 106-112.
- [20] Bar Y., Diamant I., Wolf L., Greenspan H., Deep learning with non-medical training used for chest pathology identification, *Medical Imaging 2015: Computer-Aided Diagnosis*, DOI: 10.1117/12.2083124.
- [21] Antony J., McGuinness K., O'Connor N.E. and Moran K., Quantifying Radiographic Knee Osteoarthritis Severity using Deep Convolutional Neural Networks, *2016 23rd International Conference on Pattern Recognition (ICPR)*, Cancun, 2016, 1195-1200.
- [22] Çiçek Ö., Abdulkadir A., Lienkamp S. S., Brox T., Ronneberger O., 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation, *arXiv:1606.06650v1*, 2016.
- [23] Arı A., Hanbay D., Bölgesel evrimsel sinir ağı tabanlı MR görüntülerinde tümör tespiti, *Gazi Üniversitesi Mühendislik Mimarlık Dergisi*, 2018, **34**(3), 395-408.

- [24] Budak Ü., SegNet Mimarisi ile Bilgisayarlı Tomografi Görüntülerinden Karaciğer Bölgesinin Bölütlenmesi, *Fırat Üniversitesi Müh. Bil. Dergisi*, 2019, **31**(1), 215-222.
- [25] Doğan M. S., Bitkilerde Görülen Hastalıkların Derin Öğrenme Yöntemleriyle Tespiti Ve Sınıflandırılması, Yüksek Lisans Tezi, Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Yalova, 584044.
- [26] Deng L., Yu D., Deep Learning: Methods and Applications, *Foundations and Trends in Signal Processing*, 2013, **7**(3-4), 197-387.
- [27] Ivakhnenko A. L. V, Cybernetic predicting devices, *Purdue Univ Lafayette Ind School Of Electrical Engineering*, 1965.
- [28] Şeker A., Diri B., Balık, H. H., Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi*, 2017, **3**(3), 47-64,.
- [29] Schmidhuber J., Deep learning in neural networks: An overview, *Neural Networks*, 2015, 85-117.
- [30] Xu Z., Sun J., Model-driven deep-learning, *National Science Review*, 2017, **5**(1), 22-24.
- [31] Schroff F., Kalenichenko D, Philbin J., FaceNet: A Unified Embedding for Face Recognition and Clustering, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Temmuz-2015.
- [32] Wu Y. ve diğ, Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation, *arXiv:1609.08144*, 2016.
- [33] Silver D. Ve diğ, Mastering the game of Go with deep neural networks and tree search, *Nature*, 2016, **529**(7587), 484.
- [34] McCulloch W. S., Pitts W. H. A logical calculus of the ideas immanent in nervous activity, *The Bulletin of Mathematical Biophysics*, 1943, **5**(4), 115-133.
- [35] Nابیev V., *Yapay Zeka*, 2. Baskı, Seçkin Yayıncılık, Ankara, 2005.
- [36] Wikipedia, [https://tr.wikipedia.org/wiki/Sinir\\_hücre\\_i](https://tr.wikipedia.org/wiki/Sinir_hücre_i) (Ziyaret Tarihi: 03 Mart 2020).
- [37] Yao X., Evolving Artificial Neural Networks, *Proceedings of the IEEE*, 1999, **87**(9), 1423-1447.
- [38] Çayıroğlu İ., İleri Algoritma Analizi-5 Yapay Sinir Ağları, <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf> (Ziyaret tarihi: 20 Mart 2020).

- [39] Öztemel E., Yapay Sinir Ağları, 3.Baskı, Papatya Yayıncılık, İstanbul, 2012.
- [40] Amidi s., CS 229 - Makine Öğrenimi, <https://stanford.edu/~shervine/1/tr/teaching/cs-229/cheatsheet-unsupervised-learning> (Ziyaret tarihi: 20 Mart 2020).
- [41] Orhan U., Makine Öğrenmesi, <https://bmb.cu.edu.tr/uorhan/DersNotu/Ders01.pdf> (Ziyaret tarihi: 20 Mart 2020).
- [42] LeCun Y., Bengio Y., Hinton G., Deep learning, *Nature*, 2013, **521**(7553), 436-444.
- [43] Bengio Y., LeCun Y., Scaling Learning Algorithms towards AI, *Large-Scale Kernel Machines*, 2007, **34**(5), 1-41.
- [44] İnik Ö., Ülker E., Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 2017, **6**(3), 85-104.
- [45] LeCun Y., Bottou L., Bengio Y., Haffner P., Gradient-Based Learning Applied to Document Recognition, *Proceedings of the IEEE*, 1998, **86**(11), 2278-2324.
- [46] Szegedy C., Toshev A., Erhan D., Deep Neural Networks for Object Detection, *Advances in neural information processing systems*, 2013, 2553-2561.
- [47] Kızrak M. A., Derine Daha Derine: Evrişimli Sinir Ağları, Medium, <https://medium.com/@ayyucekizrak/derine-daha-derine-evrişimli-sinir-ağları-2813a2c8b2a9> (20 Şubat 2020).
- [48] Mehrotra R., Namuduri K. R., Gabor filter-based edge detection, *Pattern Recognition*, 1992, **25**(12), 1479-1494.
- [49] Prewitt J. M. S., Object Enhancemet and Extraction, *Picture Processing and Psychopictorics*, 1970, **10**(1), 75-149.
- [50] Sobel I., Camera Models and Machine Perception, *Stanford Univ Calif Dept of Computer Science*, 1970.
- [51] Canny J. F., A Computational Approach To Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1986, **8**(6), 679-700.
- [52] Marr D., Hilderth E., Theory of edge detection, *Proceedings of the Royal Society of London. Series B. Biological Sciences*, 1985, **207**(1167), 187-217.
- [53] Aybar E., Sobel İşleci Kullanılarak Renkli Görüntülerde Kenar Bulma, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 2008, **8**(1), 205-207

- [54] Rubik's Code, <https://rubikscore.net/2018/02/26/introduction-to-convolutional-neural-networks/> (Ziyaret Tarihi: 19 Şubat 2020).
- [55] Kızrak M. A., Bolat B., Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma, *Bilişim Teknolojileri Dergisi*, 2018, 11(3), 263-286.
- [56] Altan G., DeepGraphNet: Grafiklerin Sınıflandırılmasında Derin Öğrenme Modelleri, *Avrupa Bilim ve Teknoloji Dergisi*, 2019, 319-329.
- [57] Pennington J., Schoenholz S., Ganguli S., Resurrecting the sigmoid in deep learning through dynamical isometry: theory and practice, *Advances in Neural Information Processing Systems 30*, 2017, 4785-4795.
- [58] Zhang C., Woodland P.C., DNN speaker adaptation using parameterised sigmoid and ReLU hidden activation functions, *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, China, 2016.
- [59] Chen J. C., Patel V. M., Chellappa R. Unconstrained Face Verification using Deep CNN Features, *IEEE Winter Conference on Applications of Computer Vision (WACV)*, Lake Placid - NY, USA, 2016.
- [60] Agarap A. F., Deep Learning using Rectified Linear Units, *arXiv preprint arXiv:1803.08375*, 2019.
- [61] LeCun Y. ve diğ., Hardwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning, *IEEE Communications Magazine*, 1989, 27(11), 41-46.
- [62] Hinton G. E., ve diğ., Improving Neural Networks by Preventing Co-adaptation of Feature Detectors, *arXiv:1207.0580*, 2012.
- [63] Krizhevsky A., Sutskever I., Hinton G. E., ImageNet Classification with Deep Convolutional Neural Networks, *Advances in neural information processing systems*, 2012, 1097-1105.
- [64] Glorot X., Bengio Y., Understanding the difficulty of training deep feedforward neural networks, *Proceedings of the thirteenth international conference on artificial intelligence and statistics (AISTATS)*, Italy, 2010.
- [65] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, 2016, 770-778.
- [66] Russakovsky O. ve diğ., ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision (IJCV)*, 2015, 115(3), 211-252.
- [67] Ronneberger O., Fischer P., Brox T., U-Net: Convolutional Networks for Biomedical Image Segmentation, *International Conference on Medical image computing and computer-assisted intervention*, Springer, Cham, 2015.



- [68] Cardona, A. ve diğ, An integrated micro-and macroarchitectural analysis of the Drosophila brain by computer-assisted serial section electron microscopy, *PLoS biology*, 2010, **8**(10).
- [69] ISCI Challenge 2012, Segmentation of neuronal structures in EM stacks, [http://brainiac2.mit.edu/isbi\\_challenge/](http://brainiac2.mit.edu/isbi_challenge/) (Ziyaret Tarihi: 05 Nisan 2020).
- [70] He K.,Gkioxari G., Dollár P., Girshick R., Mask R-CNN, *Proceedings of the IEEE international conference on computer vision*, 2018, 2961-2969.
- [71] Mask R-CNN for Object Detection and Segmentation, [https://github.com/matterport/Mask\\_RCNN](https://github.com/matterport/Mask_RCNN) (Ziyaret Tarihi: 01 Ocak 2020).
- [72] Redmon J., Farhadi A., YOLOv3: An Incremental Improvement, *arXiv preprint arXiv:1804.02767*, 2018.
- [73] Redmon J., Farhadi A., YOLO9000: Better, Faste, Stronger, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, 6517-6525.
- [74] Yiğidim H. A., Makine Öğrenme Algoritmalarını Kullanarak Ağ Trafiğinin Sınıflandırılması, Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi,Fen Bilimleri Enstitüsü, Ankara, 2012, 316521.
- [75] Akba F., Duygu Analizinde Öznitelik Seçme Metriklerinin Değerlendirilmesi: Türkçe Film Eleştirileri, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2014, 379610.
- [76] Hui J., mAP (mean Average Precision) for Object Detection ,Medium, [https://medium.com/@jonathan\\_hui/map-mean-average-precision-for-object-detection-45c121a31173](https://medium.com/@jonathan_hui/map-mean-average-precision-for-object-detection-45c121a31173) (Ziyaret Tarihi: 03 Mart 2020).
- [77] Cohen'in Kappa Katsayısı, Wikipedi, [https://tr.wikipedia.org/wiki/Cohen%27in\\_kappa\\_katsayısı](https://tr.wikipedia.org/wiki/Cohen%27in_kappa_katsayısı) (Ziyaret Tarihi: 05 Mart 2020).
- [78] Sharib A. ve diğ, Endoscopy Disease Detection and Segmentation (2020), *IEEE Dataport*, 2020.
- [79] Chetlur S. ve diğ, cuDNN: Efficient Primitives for Deep Learning, *arXiv:1410.0759v3*, 2014.
- [80] TensorFlow, <https://www.tensorflow.org/> (Ziyaret Tarihi: 02 Şubat 2020).

## KİŞİSEL YAYINLAR VE ESERLER

- [1] Çelikhası C., Sayar A., Ulu A., *DNA Dizilerinin Graf Benzetim Yolu ile Karşılaştırılması*, Veri Bilimi, 2018, **1**(1), 15-19.
- [2] Ulu A., Sayar A., Çelikhası C., *Graf Eşleme Algoritmalarından FastPFP'nin İncelenmesi*, International Conference on Data Science and Applications (ICONDATA), Yalova Üniversitesi, Yalova, 4-7 Ekim 2018.



## ÖZGEÇMİŞ

İlköğrenimini İstanbul’da, orta ve lise öğrenimini ise Kocaeli’nde tamamladı. 2004 yılında girdiği Pamukkale Üniversitesi Bilgisayar Sistemleri Öğretmenliğinden 2008 yılında mezun oldu. 2009 yılında Bilişim Teknolojileri Öğretmeni olarak Ardahan’ın Göle ilçesine atandı. 2010 yılında Kocaeli İzmit Meslekî ve Teknik Anadolu Lisesi’ne tayin olundu. 2014 yılında Alikahya Fatih Ortaokuluna, 2015 yılında Hereke Meslekî ve Teknik Anadolu Lisesine tayin olundu. 2019 yılında İzmit Bilim ve Sanat Merkezinde Robotik Danışmanı olarak göreve başlamış olup halen bu görevine devam etmektedir.

