



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



TIBBİ GÖRÜNTÜ İŞLEMEDE KAPSÜL
AĞLAR

AHMET SOLAK

DOKTORA TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

HAZİRAN-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ahmet SOLAK tarafından hazırlanan ‘‘Tıbbi Grnt İřlemele Kapsl Ađlar’’ adlı tez alıřması 23/06/2023 tarihinde ařađıdaki jri tarafından oy birliđi ile Konya Teknik niversitesi Lisansst Eđitim Enstits Elektrik-Elektronik Mhendisliđi Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiřtir.

Jri yeleri

İmza

Başkan

Prof. Dr. Seral ZŐEN

.....

Danıřman

Doç. Dr. Rahime CEYLAN

.....

ye

Dr. đr. yesi Hseyin Oktay ALTUN

.....

ye

Dr. đr. yesi Gzin ZMEN

.....

ye

Dr. đr. yesi Hasan KOYUNCU

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlt UYAN
Enstit Mdr

Bu tez alıřması đretim yesi Yetiřtirme (YP) programı koordinatrlđ tarafından 2018-YP-033 nolu proje ile desteklenmiřtir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Ahmet SOLAK

Tarih: 23.06.2023

ÖZET

DOKTORA TEZİ

TIBBİ GÖRÜNTÜ İŞLEMEDE KAPSÜL AĞLAR

Ahmet SOLAK

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Rahime CEYLAN

2023, 130 Sayfa

Jüri

Doç. Dr. Rahime CEYLAN
Prof. Dr. Seral ÖZŞEN
Dr. Öğr. Üyesi Hüseyin Oktay ALTUN
Dr. Öğr. Üyesi Güzin ÖZMEN
Dr. Öğr. Üyesi Hasan KOYUNCU

Bu doktora tezi, farklı görüntüleme yöntemlerinden elde edilen tıbbi görüntülerin otomatik sınıflandırılması ve segmentasyonu için Bilgisayar Destekli Tanı (BDT) sistemlerinin geliştirilmesine odaklanmaktadır. Tıbbi görüntüleme, vücudun iç yapılarını ve işlevlerini görselleştirmek için invazif olmayan araçlar sağlayarak sağlık hizmetlerinde kritik bir rol oynamaktadır. Bununla birlikte, tıbbi görüntülerin radyologlar tarafından analizi ve yorumlanması genellikle öznel ve zaman alıcıdır. Bu nedenle bu tez, tıbbi görüntülerdeki ilgi alanlarının tespitini ve sınıflandırılmasını otomatikleştirmek için yapay zekanın, özellikle de derin öğrenme modellerinin kullanımını araştırmaktadır.

Tez, her biri farklı bir tıbbi görüntüleme yöntemine odaklanan dört çalışma içermektedir. İlk çalışma, mamogram görüntülerindeki iyi huylu/kötü huylu kitlelerin klasik Konvolüsyonel Sinir Ağları (KSA) ve transfer öğrenme modelleri kullanılarak sınıflandırılmasını ve ardından bu tezde geliştirilen kapsül ağ modeli kullanılarak sınıflandırılmasını içermektedir. İkinci çalışma, modifiye edilmiş bir U-Net modeli kullanarak kolonoskopi görüntülerindeki poliiplerin segmentasyonuna ve segmentasyon performansını optimize etmek için farklı parametrelerin analizine sonrasında kapsül ağ tabanlı bir segmentasyon modelinin performansına odaklanmaktadır. Üçüncü çalışmada, abdominal MR görüntülerindeki iyi huylu/kötü huylu adrenal lezyonların hem sınıflandırılması hem de segmentasyonu incelenmiştir. Sınıflandırma için farklı ilgi bölgeleri çıkarılmış, kapsül ağ tabanlı ve KSA tabanlı modeller kullanılarak ayrı çalışmalar yapılmıştır. Segmentasyon için klasik U-Net modeli modifiye edilerek yeni bir model önerilmiş, farklı parametrelerin ve kapsül ağ tabanlı segmentasyon modelinin performans üzerindeki etkisi değerlendirilmiştir. Son olarak, X-ışını görüntüleri kullanılarak çocuklarda pnömoni sınıflandırması için özel bir kapsül ağ yapısı önerilmiştir.

Tüm çalışmalar literatürdeki benzer çalışmalarla veya en son modellerle karşılaştırılmış ve üstünlükleri gösterilmiştir. Genel olarak bu tez, tıbbi görüntülerin otomatik sınıflandırılması ve segmentasyonu için tıbbi teşhislerin doğruluğunu, verimliliğini ve tutarlılığını potansiyel olarak artırabilecek yeni derin öğrenme modelleri sunmaktadır.

Anahtar Kelimeler: Derin Öğrenme, Kapsül Ağlar, Konvolüsyonel Sinir Ağları, Medikal Görüntü, Medikal Görüntü Sınıflandırması, Medikal Görüntü Segmentasyonu, U-Net

ABSTRACT

PhD THESIS

CAPSULE NETWORKS IN MEDICAL IMAGE PROCESSING

Ahmet SOLAK

Konya Technical University
Institute of Graduate Studies
Department of Electrical & Electronics Engineering

Advisor: Assoc. Prof. Dr. Rahime CEYLAN

2023, 130 Pages

Jury

Assoc. Prof. Dr. Rahime CEYLAN
Prof. Dr. Seral ÖZŞEN
Asst. Prof. Dr. Hüseyin Oktay ALTUN
Asst. Prof. Dr. Güzin ÖZMEN
Asst. Prof. Dr. Hasan KOYUNCU

This PhD thesis focuses on the development of Computer Aided Diagnosis (CAD) systems for the automatic classification and segmentation of medical images obtained from different imaging modalities. Medical imaging plays a critical role in healthcare by providing non-invasive tools to visualize the internal structures and functions of the body. However, the analysis and interpretation of medical images by radiologists is often subjective and time consuming. This thesis therefore explores the use of artificial intelligence, specifically deep learning models, to automate the detection and classification of regions of interest in medical images.

The thesis includes four studies, each focusing on a different medical imaging modality. The first study involves the classification of benign/malignant masses in mammogram images using classical Convolutional Neural Networks (CNN) and transfer learning models, followed by classification using the capsule network model developed in this thesis. The second study focuses on the segmentation of polyps in colonoscopy images using a modified U-Net model and the performance of a capsule network-based segmentation model after analysis of different parameters to optimize the segmentation performance. In the third study, both classification and segmentation of benign/malignant adrenal lesions in abdominal MR images are investigated. For classification, different regions of interest are extracted, and separate studies are performed using capsule network-based and KSA-based models. For segmentation, a new model is proposed by modifying the classical U-Net model and the effect of different parameters and the capsule network-based segmentation model on the performance is evaluated. Finally, a special capsule network structure is proposed for pneumonia classification in children using X-ray images.

All studies are compared with similar studies in the literature or with the latest models and their advantages are shown. Overall, this thesis presents new deep learning models for automatic classification and segmentation of medical images, which can potentially improve the accuracy, efficiency and consistency of medical diagnoses.

Keywords: Deep Learning, Capsule Networks, Convolutional Neural Networks, Medical Image, Medical Image Classification, Medical Image Segmentation, U-Net

ÖNSÖZ

Öncelikle bütün çalışmalarımnda değerli bilgi ve tecrübeleriyle bana yol gösteren, gerekli araştırma ve geliştirme çabalarımnda yardımlarını esirgemeyen danışmanım Konya Teknik Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği öğretim üyesi Doç. Dr. Rahime CEYLAN hocama sonsuz teşekkürlerimi sunarım.

Başta doktora süreci içerisinde kaybettiğim babaannem ve dedem olmak üzere tüm eğitim-öğretim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen varlıklarıyla onur duyduğum aileme minnettarım. Bu süreç içerisinde hayatıma giren doktora sürecinin zorlu dönemlerinde yanımda olan eşim Dr. Öğr. Üyesi Fatma Zehra SOLAK'a teşekkürü borç bilirim. Yaklaşık bir yıl önce hayatımıza giren evimizin değerlisi kızım İdil SOLAK'a da sevgilerimi sunuyorum.

Son olarak tüm eğitim hayatım boyunca olduğu gibi doktora eğitimim boyunca da desteklerini esirgemeyen yüce Türk milletime ve devletime şükranlarımı sunarım.

Ahmet SOLAK
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1. Mamogram Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi	2
1.2. Manyetik Rezonans (MR) Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi.....	3
1.3. Kolonoskopi Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi	4
1.4. Röntgen Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi	5
2. KAYNAK ARAŞTIRMASI	6
2.1. Görüntü İşleme için Kullanılan Derin Öğrenme Ağ Modelleri.....	6
2.2. MIAS Veri Setiyle İlgili Yapılan Çalışmalar	12
2.3. Polip Veri Setiyle İlgili Yapılan Çalışmalar	14
2.4. Sürrenal Veri Setiyle İlgili Yapılan Çalışmalar	15
2.5. Pnömoni Veri Setiyle İlgili Yapılan Çalışmalar	18
3. MATERYAL VE YÖNTEM.....	20
3.1. Materyal	20
3.1.1. Mamogram görüntü veri seti.....	20
3.1.2. Polip görüntü veri seti.....	21
3.1.3. Abdomen görüntü veri seti	22
3.1.4. Pnömoni (Zatürre) görüntü veri seti	23
3.2. Veri Setleri Üzerinde Kullanılan Ön İşlemler	24
3.2.1. Ayrık dalgacık dönüşümü (ADD).....	24
3.2.2. Ayrık kosinüs dönüşümü (AKD).....	25
3.2.3. Kontrast sınırlı uyarlamalı histogram eşitleme (KSUHE).....	26
3.2.4. Görüntü füzyonu	27
3.3. Metotlar.....	27
3.3.1. Konvolüsyonel sinir ağları (KSA)	27
3.3.2. U-Net	34
3.3.3. Modifiye edilmiş U-Net.....	38
3.3.4. Kapsül ağlar	40
3.3.5. Önerilen kapsül sınıflandırma ağ yapısı	46
3.3.6. Önerilen kapsül segmentasyon ağı	47
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	49

4.1. Tez Çalışmasında Kullanılan İstatistiksel Metrikler.....	49
4.2. Mamogram Veri Setiyle Yapılan Sınıflandırma Çalışması	51
4.2.1. KSA ve transfer öğrenmesi kullanılarak gerçekleştirilen sınıflandırma çalışması.....	53
4.2.2. Kapsül ağlar kullanılarak gerçekleştirilen sınıflandırma çalışması	58
4.3. Polip Veri Setiyle Yapılan Çalışmalar	59
4.3.1. U-Net modelleriyle yapılan segmentasyon çalışmaları	60
4.3.2. Kapsül ağıyla yapılan segmentasyon çalışması	70
4.4. Abdomen Veri Setiyle Yapılan Çalışmalar	71
4.4.1. Abdomen veri setiyle yapılan segmentasyon çalışması.....	71
4.4.2. Abdomen veri setiyle yapılan segmentasyon çalışmasının sonuçları.....	75
4.4.3. Abdomen veri setiyle yapılan sınıflandırma çalışmaları	88
4.5. Pnömoni Veri Setiyle Yapılan Çalışmalar	101
4.5.1. Pnömoni veri setiyle yapılan sınıflandırma çalışması	101
4.5.1. Pnömoni veri setiyle yapılan sınıflandırma çalışmasının sonuçları.....	103
5. SONUÇLAR VE ÖNERİLER.....	108
5.1. Sonuçlar	108
5.2. Öneriler	111
KAYNAKLAR	112
EKLER	118

SİMGELER VE KISALTMALAR

Simgeler

c_{ij}	: Eşleşme katsayıları
f	: Filtre boyutu
l	: Düşük seviye kapsül katmanı
$l+1$: Yüksek seviye kapsül katmanı
L_{Toplam}	: Toplam kayıp
L_{Marj}	: Marj kaybı
$L_{Yeniden\ Yapılandırma}$: Yeniden yapılandırma kaybı
n	: Giriş görüntüsü boyutu
p_0	: Gözlenen uyumluluk oranı
p_e	: Tesadüfi uyumluluk oranı
r	: Algoritma tekrar sayısı
s	: Kaydırma adımı
s_j	: Ezme aktivasyon fonksiyonunun giriş vektörü
$ s_j $: Ezme aktivasyon fonksiyonunun giriş vektörünün normu
p	: Doldurma (Padding)
u_i	: Kapsül ağınnın giriş vektörleri
\hat{u}_{ji}	: Tahmin vektörleri
v_j	: Ezme aktivasyon fonksiyonunun çıkış vektörü
W_{ij}	: Dönüşüm matrisleri
X_{min}	: X eksenindeki minimum piksel değeri
X_{maks}	: X eksenindeki maksimum piksel değeri
Y_{min}	: Y eksenindeki minimum piksel değeri
Y_{maks}	: Y eksenindeki maksimum piksel değeri

Kısaltmalar

3B	: 3 Boyutlu
ADD	: Ayrık Dalgacık Dönüşümü
AGF	: Alçak Geçiren Filtre
AHE	: Adaptif Histogram Eşitleme
AKD	: Ayrık Kosinüs Dönüşümü
ASA	: Artık Sinir Ağı
ATUS	: Adrenal Tümör Segmentasyonu
MKDD	: Meme Kanseri Dijital Deposu
BDT	: Bilgisayar Destekli Tanı
BT	: Bilgisayarlı Tomografi
ÇD	: Çapraz Doğrulama
ÇÜA	: Çekişmeli Üretici Ağlar
DKSA	: Derin Konvolüsyon Sinir Ağı
TMDV	: Tarama Mamografisi için Dijital Veritabanı
DK	: Dice Katsayısı
DÇBA	: Derin Çok-Ölçekli Benzerlik Ağı
DN	: Doğru Negatif
DOĞ	: Doğruluk
DP	: Doğru Pozitif
DPO	: Doğru Pozitif Oranı

DUY	: Duyarlılık
DVM	: Destek Vektör Makinaları
EAA	: Eğri Altındaki Alan
GDEOM	: Gri Düzeyli Eş Oluşum Matrisi
HM	: Hausdorff Mesafesi
İA	: İlgi Alanı
İÇE	: İkili Çapraz Entropi
JO	: Jaccard Oranı
KES	: Kesinlik
KSA	: Konvolüsyonel Sinir Ağı
KSUHE	: Kontrast Sınırlı Uyarlamalı Histogram Eşitleme
MATLAB	: Matrix Laboratory
MIAS	: Mammographic Image Analysis Society
BÜOK	: Birleşim Üzerinde Ortalama Kesişim
MR	: Manyetik Rezonans
OKH	: Ortalama Kare Hata
ÖZG	: Özgüllük
ReLU	: Rektifiye Doğrusal Birim
PReLU	: Parametrik Rektifiye Doğrusal Birim
SPTRY	: Süper Piksel Tabanlı Rastgele Yürüyüş
TBK	: Tam bağlantılı katman
TKA	: Tam Konvolüsyonel Ağ
YBİ	: Yapısal Benzerlik İndeksi
YGF	: Yüksek Geçiren Filtre
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YPO	: Yanlış Pozitif Oranı
YSA	: Yapay Sinir Ağı

1. GİRİŞ

Tıbbi görüntüleme, sağlık çalışanlarının insan vücudunun iç yapılarını ve işlevlerini görselleştirmesini sağladığı için hastalıkların teşhis ve tedavisinde kritik bir rol oynamaktadır. Dijital görüntüleme teknolojilerinin ortaya çıkmasıyla birlikte, üretilen tıbbi görüntü verilerinin miktarı önemli ölçüde artmıştır. Bu verilerin manuel olarak analiz edilmesi zaman alıcı ve hataya açıktır. Bu nedenle, yapay zeka tekniklerinin, özellikle de derin öğrenmenin kullanımı, tıbbi görüntü analizini otomatikleştirmek için umut verici bir yaklaşım olarak ortaya çıkmıştır.

Makine öğreniminin bir alt alanı olan derin öğrenme, verilerin hiyerarşik temsillerini öğrenmek ve çıkarmak için birden fazla gizli katmana sahip yapay sinir ağlarının kullanılmasını içerir. Tıbbi görüntülerde derin öğrenmenin gelişimi, konvolüsyonel sinir ağlarının (KSA) tıbbi görüntü analizine uygulandığı 2010'ların başlarına kadar uzanmaktadır. KSA'lar, görüntülerden uzamsal özellikleri öğrenme yetenekleri nedeniyle görüntü verilerini analiz etmede özellikle etkilidir.

O zamandan beri, derin öğrenme teknikleri segmentasyon, sınıflandırma, algılama ve kayıt dahil olmak üzere tıbbi görüntüleme uygulamalarında yaygın olarak benimsenmiştir. U-Net (Ronneberger ve ark., 2015), ResNet (He ve ark., 2016) ve VGGNet (Simonyan ve Zisserman, 2014) gibi çeşitli derin öğrenme mimarileri önerilmiş ve tıbbi görüntü analizine uygulanmıştır. Bu mimariler bilgisayarlı tomografi (BT), manyetik rezonans (MR) ve ultrason dahil olmak üzere çeşitli tıbbi görüntüleme modalitelerinde umut verici sonuçlar göstermiştir.

Hinton ve arkadaşları tarafından 2017 yılında tanıtılan bir tür derin öğrenme mimarisi olan kapsül ağlar, tıbbi görüntü analizinde geleneksel KSA'lara göre potansiyel avantajlar göstermiştir. Kapsül ağlar, KSA'ların sınırlamalarını, özellikle de nesne pozunu ve deformasyonundaki varyasyonları kavramadaki yetersizliklerini ele almak için tasarlanmıştır.

Kapsül ağlar, bir nesnenin konum, yönelim ve deformasyon gibi örnekleme parametrelerini temsil eden nöron grupları olan kapsülleri kullanır. Kapsüller birbirlerine dönüşüm matrisleri aracılığıyla bağlanarak nesnelere arasındaki ilişkileri hiyerarşik bir şekilde öğrenmelerini sağlar. Bu hiyerarşik temsilin, KSA'lar tarafından öğrenilen özellik haritalarından daha yorumlanabilir olduğuna inanılmaktadır.

Tıbbi görüntülemede, kapsül ağlar segmentasyon, sınıflandırma ve tespit gibi çeşitli uygulamalarda umut vaat etmektedir. Örneğin kapsül ağlar, geleneksel

KSA'lerden daha yüksek doğruluk elde ettikleri BT taramalarında akciğer nodülü tespitine uygulanmıştır (Afshar ve ark., 2020). Buna ek olarak, kapsül ağlar mamogramlarda meme kanseri tespitinde potansiyel göstermiş ve duyarlılık ve özgüllük açısından KSA'lerden daha iyi performans göstermiştir (Kavitha ve ark., 2021).

Sonuç olarak, derin öğrenme tıbbi görüntü analizini otomatikleştirmek için umut verici bir yaklaşım olarak ortaya çıkmıştır. Çeşitli derin öğrenme mimarileri önerilmiş ve bu mimariler tıbbi görüntüleme uygulamalarına uygulanmıştır. Özellikle kapsül ağlar, tıbbi görüntü analizinde, özellikle nesne pozu ve deformasyonundaki varyasyonları ele almada geleneksel KSA'lara göre potansiyel avantajlar göstermiştir. Bu nedenle kapsül ağlar, tıbbi görüntü analizinin ilerletilmesinde ve sağlık hizmeti sonuçlarının iyileştirilmesinde önemli bir rol oynayabilir.

Bu tez çalışması kapsamında derin öğrenme ile farklı medikal görüntüler üzerinde sınıflandırma ve segmentasyon çalışmaları gerçekleştirilmiştir. Çalışmalarda sınıflandırma ve segmentasyon için literatürde yer alan modellerin yanı sıra tez çalışması sırasında geliştirilen ve önerilen kapsül ağ modellerine de yer verilmiştir. Bu amaçla her veri seti için farklı bir BDT sistemi tasarlanmış ve bu sistemlerin performansları incelenmiştir. Tez içerisinde mamogram, MR, kolonoskopi ve röntgen görüntülerinden oluşan farklı veri setleri üzerinde çalışmalar gerçekleştirilmiştir.

1.1. Mamogram Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi

Dünya Kanser Araştırmaları Fonunun verilerine göre 2018 yılında dünya genelinde 2,088,849 kadında yeni meme kanseri vakası teşhis edilmiştir. Meme kanseri bu rakamla 2018 yılında kadınlarda görülen kanser vakaları içerisinde %25.4'lük oranla ilk sırada yer almaktadır (International, 2019). Ayrıca; Amerikan Kanser Birliğinin araştırmasına göre 2019 yılında Amerika'da yaklaşık 268,600 kadında yeni vaka ve yaklaşık 41,760 kadının meme kanserinden dolayı ölümü beklenmektedir (Society, 2020).

Mamografi, meme kanserini taramak için kullanılan tanısal bir görüntüleme yöntemidir. Memenin iç yapısının ayrıntılı görüntülerini üreten düşük dozlu bir röntgendir. Bu görüntüleme yöntemi, meme kanserinin göstergesi olabilecek topaklar, kistler ve kalsifikasyonlar dahil olmak üzere meme dokusundaki değişiklikleri saptayabilir (Götzsche ve Jørgensen, 2013).

Yapay zekanın mamografide kullanılması, meme kanseri tespitinin doğruluğunu, hızını ve tutarlılığını geliştirmeyi amaçlar. Derin öğrenme modelleri de dahil olmak üzere yapay zeka algoritmaları, mamografi görüntülerini analiz etmek ve şüpheli kitleler veya kireçlenmeler gibi endişe verici alanları belirlemek için eğitilebilir. Bazı durumlarda bu modeller, bu alanlarda malignite olasılığını ölçmek ve sınıflandırmak için de kullanılabilir ve böylece radyologlara daha doğru ve verimli teşhisler için ek bilgiler sağlanır. Mamografideki bazı yapay zeka örnekleri arasında BDT sistemleri ve meme yoğunluğu değerlendirmesi için derin öğrenme modelleri yer almaktadır. Bununla birlikte, yapay zekanın mamografide kullanımının hala erken bir aşamada olduğu, klinik geçerliliği ve güvenilirliğini sağlamak için daha fazla araştırma ve doğrulamaya ihtiyaç duyduğu göz ardı edilmemelidir.

Bu tez çalışmasında, mamografi görüntü analizi ile ilgili araştırma ve akademik çalışmalarda yaygın olarak kullanılan Mini-MIAS (Mammographic Image Analysis Society) veri seti kullanılarak iyi huylu ve kötü huylu kitle sınıflandırması yapılmıştır.

1.2. Manyetik Rezonans (MR) Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi

Adrenal lezyonlar, böbreklerin üstünde yer alan adrenal bezlerde oluşan anormal büyümeleri veya kitleleri ifade eder. Lezyonlar iyi huylu (kansersiz olmayan) veya kötü huylu (kansersiz) olabilir. Lezyonun tipine, boyutuna, konumuna ve ayrıca hormon üretimi üzerindeki etkisine bağlı olarak çeşitli semptomlara neden olabilmektedir. Yaygın adrenal lezyon tipleri arasında adrenal adenomlar, adrenokortikal karsinomlar, feokromositomalar ve miyelolipomlar bulunur. Adrenal lezyonların teşhisi genellikle BT taramaları, MR ve biyopsi gibi görüntüleme testleri ile yapılır. Adrenal lezyonların tedavisi, lezyonun tipine ve evresine bağlı olarak cerrahi olarak çıkarılmasını, hormon tedavisini veya radyasyon tedavisini içerebilir (Mendiratta-Lala ve ark., 2017).

MR, vücudun ayrıntılı görüntülerini oluşturmak için güçlü manyetik alanlar ve radyo dalgaları kullanan, invazif olmayan bir tanısal görüntüleme tekniğidir. X-ışınları veya BT taramalarının aksine, MR iyonlaştırıcı radyasyon kullanmaz, bu da onu çeşitli doku ve organları görüntülemek için güvenli bir seçenek haline getirir. Yumuşak dokuların yüksek çözünürlüklü görüntülerini sağlayarak tümörler, sinir hasarı, iltihaplanma, kalp ve damar hastalıkları gibi çok çeşitli durumların teşhisinde faydalı bir

araç haline gelmektedir. Ek olarak, tümörler gibi belirli dokuların görünürliğini artırmak için kontrast maddeler kullanılabilir (Vlaardingerbroek ve Boer, 2013).

Tez çalışması kapsamında, T1 ve T2 ağırlıklı abdomen MR görüntülerinden adrenal lezyonların hem sınıflandırılması hem de segmentasyonuna yönelik çalışmalar gerçekleştirilmiştir.

1.3. Kolonoskopi Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi

Polipler, kolon veya rektumun iç astarında meydana gelen küçük büyümelelerdir. Genellikle kolonun içini incelemek için kullanılan bir prosedür olan kolonoskopi sırasında bulunurlar. Poliplerin boyutları birkaç milimetreden birkaç santimetreye kadar değişebilir, iyi huylu veya kanser öncesi (kansere dönüşme potansiyeline sahip) olarak sınıflandırılabilirler. Poliplerin kesin nedeni tam olarak anlaşılamamıştır, ancak genellikle yaş, aile öyküsü, diyet ve sigara kullanımı gibi belirli yaşam tarzı faktörleriyle ilişkilendirilirler. Kolonoskopi sırasında bir polip bulunursa, çıkarılabilir ve ileri testler için bir laboratuvara gönderilebilir. Bazı durumlarda, polipler kanser öncesiye, karın ağrısı veya rektal kanama gibi semptomlara neden oluyorsa cerrahi olarak çıkarılması gerekebilir (Van Rijn ve ark., 2006).

Polip segmentasyonu, kolonoskopi veya BT taramalar gibi tıbbi görüntülerde polipleri tanımlama ve çevre dokudan ayırma işlemidir. Polip segmentasyonunun amacı, ileri analiz, teşhis ve tedavi için poliplerin yerini ve şeklini doğru bir şekilde belirlemektir. KSA, U-Net gibi derin öğrenme teknikleri, son yıllarda polip segmentasyonu için başarıyla uygulanmışlardır. Bu modeller, büyük miktardaki tıbbi veriden karmaşık özellikleri öğrenerek yüksek doğruluk ve sağlam performans sağlamaktadırlar. Polip segmentasyon görevlerinde, girdi tipik olarak bir kolonoskopi görüntüsüdür ve çıktı, poliplerin varlığını gösteren bir segmentasyon haritasıdır. Eğitim verileri bu modeller için önemlidir ve tipik olarak etiketli poliplere sahip açıklamalı görüntülerden oluşmaktadır.

Tez çalışmasında, CVC-ClinicDB (612 polip görüntüsü ve maskesi) (Bernal ve ark., 2015), Etis-Larib (196 polip görüntüsü ve maskesi) (Silva ve ark., 2014) ve Kvasir-Seg (1000 polip görüntüsü ve maskesi) (Jha ve ark., 2020) veri setleri kullanılmıştır.

1.4. Röntgen Görüntüleri ile Gerçekleştirilen Çalışmanın Amacı ve Önemi

Zatürre (pnömoni), akciğerleri etkileyen ve özellikle çocuklarda yaşamı tehdit edebilen ciddi bir hastalıktır. Akciğerlerdeki hava keselerinin iltihaplanmasından kaynaklanır, bu da sıvı birikmesine ve nefes almada zorluğa yol açar. Çocuklarda pnömoninin en yaygın nedeni bakteriyel veya viral bir enfeksiyondur, ancak hava kirliliği ve zayıflamış bağışıklık sistemleri gibi diğer faktörler de rol oynayabilir. Çocuk pnömonisinin semptomları arasında sürekli öksürük, yüksek ateş, hızlı nefes alma, göğüs ağrısı, iştah ve enerji seviyelerinde azalma sayılabilir. Zatürreyi teşhis etmek için doktor fiziki muayene yapabilir, çocuğun nefesini stetoskopta dinleyebilir, göğüs röntgeni veya diğer görüntüleme testlerini isteyebilir.


Tez çalışması kapsamında yapılan çalışmada, beş yaş altı çocuklardan alınan röntgen görüntülerinden zatürre-sağlıklı sınıflandırması yapılmıştır. Göğüs röntgeni veri seti, Guangzhou Kadın ve Çocuk Tıp Merkezi'nde bir ila beş yaşındaki pediatrik hastalardan oluşan retrospektif bir gruptan seçilmiştir (Kermany ve ark., 2018). Veri seti 1,583 adet sağlıklı, 4,273 adet zatürre olmak üzere toplam 5,856 adet akciğer röntgen görüntüsünden oluşmaktadır.

2. KAYNAK ARAŞTIRMASI

Bu bölümde, derin öğrenmede kullanılan modeller ve tez çalışması kapsamında kullanılan veri setleriyle alakalı yapılan çalışmalar beş bölüm halinde incelenmektedir. İlk bölümde literatürde görüntü işlemede kullanılan derin öğrenme ağ modelleri, ikinci bölümde MIAS veri setiyle yapılan çalışmalar, üçüncü bölümde sürrenal veri setiyle yapılan çalışmalar, dördüncü bölümde polip veri setiyle yapılan çalışmalar ve son olarak pnömoni veri setiyle yapılan çalışmalar incelenmektedir.

2.1. Görüntü İşleme için Kullanılan Derin Öğrenme Ağ Modelleri

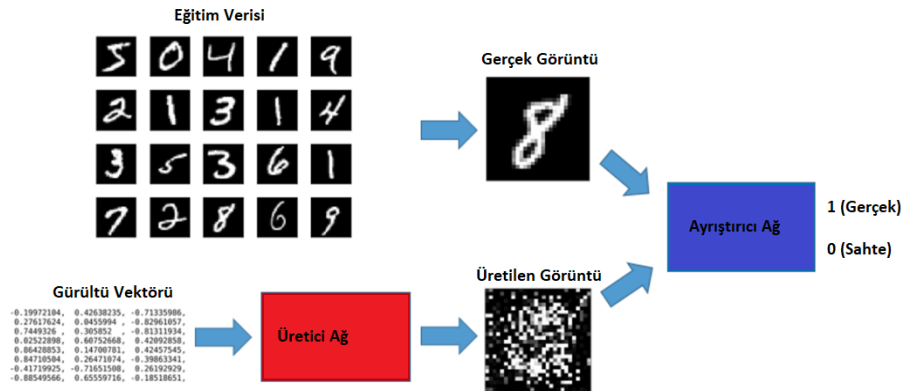
(Krizhevsky ve ark., 2012) 1,2 milyon görüntü ve 1000 farklı sınıftan oluşan ImageNet yarışmasında derin KSA'yı kullanarak AlexNet modelini geliştirmişlerdir. Şekil 2.1'de AlexNet yapısı verilmiştir. Şekil 2.1'de görüleceği gibi model temel olarak beş konvolüsyon ve üç tam bağlantılı katmandan oluşmaktadır. İlk konvolüsyon katmanı $224 \times 224 \times 3$ giriş görüntüsünü 4 piksellik bir kaydırma adımıyla $11 \times 11 \times 3$ boyutunda 96 filtreden oluşmaktadır. Bu filtreler yardımıyla elde edilen özellik haritaları aktivasyon fonksiyonundan geçer ve normalleştirilir. Sonrasında bunlara 3×3 boyutunda 2 piksellik bir kaydırma adımıyla havuzlama uygulanır. İkinci konvolüsyon katmanı girdi olarak bu çıktıyı alır ve $5 \times 5 \times 48$ boyutunda 256 filtre ile filtreler. Yine bu katman sonrasında benzer aktivasyon fonksiyonu, normalleştirme ve havuzlama işlemleri uygulanır. Üçüncü, dördüncü ve beşinci konvolüsyon katmanları, araya herhangi bir havuzlama veya normalleştirme katmanı girmeden birbirlerine bağlanır. Üçüncü konvolüsyon katmanı, ikinci konvolüsyon katmanının çıkışlarına bağlı $3 \times 3 \times 256$ boyutunda 384 filtreye sahiptir. Dördüncü konvolüsyon katmanı $3 \times 3 \times 192$ boyutunda 384 filtreye sahiptir ve beşinci konvolüsyon katmanı $3 \times 3 \times 192$ boyutunda 256 filtreye sahiptir. Beşinci konvolüsyon katmanından sonra elde edilen özellik haritalarına aktivasyon fonksiyonu, normalleştirme ve havuzlama işlemleri uygulanır. Sonrasında bu haritalar her biri 4096 nörona sahip tam bağlantılı katmanlara aktarılır. Burada son tam bağlantılı katmanın çıktısı 1000 sınıf dağılımına sahip *Softmax* aktivasyon fonksiyonundan geçirilir ve görüntünün sınıfsal olasılıkları belirlenir. Yarışmada, geliştirilen bu modelle sınıflandırma doğruluğu oranı %74.3'ten %83.6 ya çıkarılmıştır.



Şekil 2.1. AlexNet yapısı (Krizhevsky ve ark., 2012)

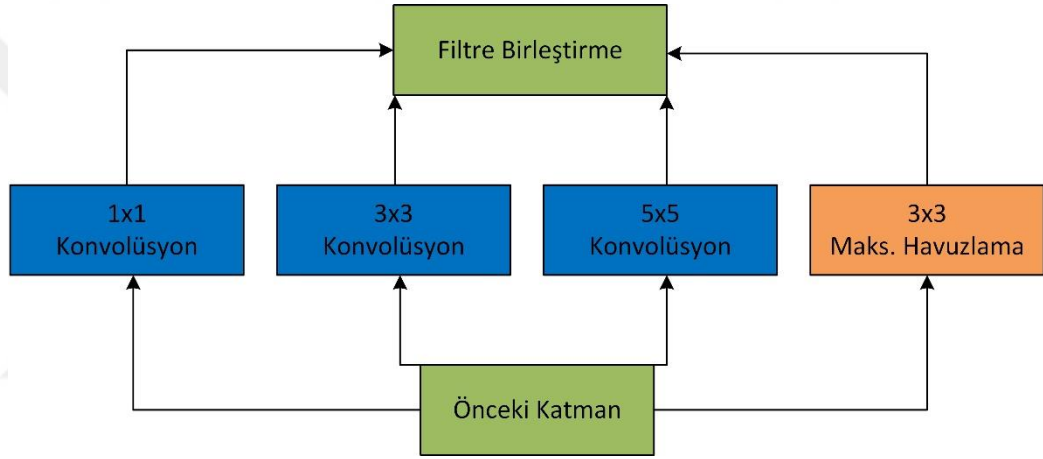
(Simonyan ve Zisserman, 2014) KSA'nın yapısında kullanılan filtreleri ve ağ derinliğini değiştirerek VGG-16 ve VGG-19 olmak üzere iki tane derin öğrenme modeli geliştirmişlerdir. Geliştirilen modeller ImageNet 2014 yarışmasında AlexNet'e göre daha başarılı sonuçlar vermiştir.

(Goodfellow ve ark., 2014) Çekişmeli Üretici Ağlar (ÇÜA) yapısını tanıtmışlardır. ÇÜA sentetik veri üretmek için kullanılan bir ağ modelidir. Şekil 2.2'de ÇÜA yapısı görülmektedir. Şekil 2.2 incelenirse bu ağ yapısı bir üretici ve bir ayrıştırıcı olmak üzere iki sinir ağından oluşmaktadır. Üretici ağ yeni veriler üretmek için eğitilirken, ayrıştırıcı ağ gerçek ve üretilen verileri ayırt etmek için eğitilir. Eğitim sırasında, üretici ağ veri örnekleri üretir ve bunlar daha sonra gerçek verilerle birlikte ayrıştırıcı ağa verilir. Ayrıştırıcı ağ daha sonra her örneğe gerçek olma olasılığını gösteren bir skor atar. Üretici ağ daha sonra parametrelerini, ayrıştırıcı ağı yanılabilecek gerçekçi veriler üretme yeteneğini geliştirmek için ayarlar. İki ağ eş zamanlı olarak eğitilir; üretici ağ daha gerçekçi veriler üretmeye çalışırken, ayrıştırıcı ağ da gerçek ve üretilmiş veriler arasında ayırım yapma konusunda daha iyi olmaya çalışır. Bu süreç, üretici ağ gerçek verilerden ayırt edilemeyen veriler üretene kadar devam eder.



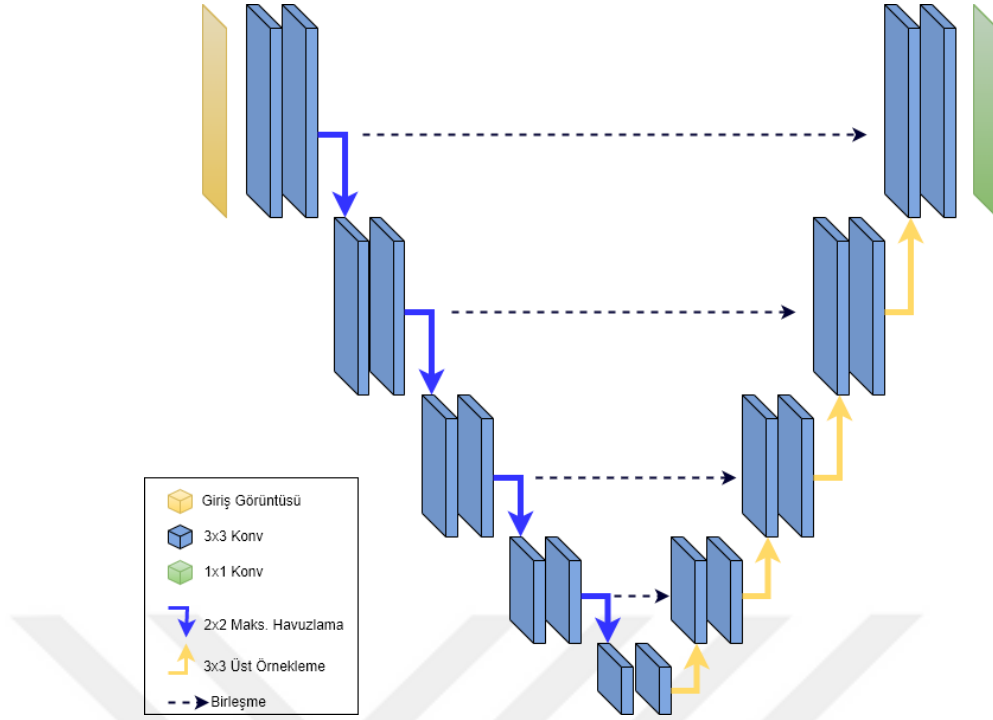
Şekil 2.2. ÇÜA yapısı

(Szegedy ve ark., 2015) özellik haritalarını çıkarmada kullanılan filtrelerin tek boyutta değil de farklı boyutlarda kullanılması ve sonrasında çıkarılan bu özellik haritalarının birleştirilmesi prensibine dayanan Inception ağı geliştirmişlerdir. Şekil 2.3'te Inception yapısına ait blok gösterim sunulmuştur. Inception ağının temel yeniliği, ağın her katmanda farklı filtre boyutlarını ve havuzlama işlemlerini aynı anda öğrenmesine olanak tanıyan ve giriş görüntüsünün çok ölçekli bir temsilini sağlayan "Inception modüllerinin" kullanılmasıdır. Inception modülleri, farklı filtre boyutlarına sahip birkaç paralel konvolüsyon katmanından ve ardından özellik haritalarının boyutluluğunu azaltan havuzlama katmanlarından oluşur. Farklı katmanların çıktıları daha sonra birleştirilir ve ağdaki bir sonraki katmana aktarılır.




Şekil 2.3. Inception yapısı (Szegedy ve ark., 2015)

(Ronneberger ve ark., 2015) medikal görüntü segmentasyonu alanında bir dönüm noktası olan U-Net modelini tanıtmışlardır. Şekil 2.4'te U-Net modelinin yapısı verilmiştir. Model temel olarak kodlayıcı ve kod çözücü olmak üzere iki kısımdan oluşmaktadır. Kodlayıcı kısımda segmente edilmek istenen görüntüden özellik haritaları çıkarılırken kod çözücü kısımda ise çıkarılan özellik haritalarından segmente edilmiş görüntü elde edilmeye çalışılır. Kod çözücünün her bir katmanında ayrıca kodlayıcı kısımdan gelen özellik haritalarıyla birlikte işlemler gerçekleştirilir.



Şekil 2.4. U-Net yapısı

(He ve ark., 2016) Artık Sinir Ağı (ASA) yapısını önermişlerdir. Sinir ağlarında katmanlar derinleştikçe başarı oranı artmaz, aksine belli bir noktadan sonra bozulmaya başlar. ASA’da bunu engellemek amacıyla ortaya çıkan bir ağ modelidir. Şekil 2.5’te ASA blokları verilmiştir. Şekil 2.5’te 3×3 filtre boyutlarını, 64 filtre sayısını temsil etmektedir. Bir artık blok, iki veya daha fazla konvolüsyon katmanından ve ardından bu katmanları atlayan bir kısayol bağlantısından oluşur. Konvolüsyon katmanlarının çıktısı, ReLU gibi doğrusal olmayan bir aktivasyon fonksiyonundan geçirilmeden önce bloğun girişine eklenir. Elde edilen çıktı daha sonra ağdaki bir sonraki katmana iletilir. Bir artık bloğundaki kestirme bağlantı, gradyanların ek katmanlardan geçmeden doğrudan bloktan akmasını sağlar, bu da derin ağlarda meydana gelebilecek kaybolan gradyan sorununun önlenmesine yardımcı olur. Artık bloklar kullanılarak, daha önceki katmanlardan gelen bilgiler korunabilir ve ağdaki daha derin katmanlara aktarılabilir, bu da karmaşık özelliklerin daha etkili bir şekilde öğrenilmesine olanak tanır.




Şekil 2.5. ASA bloğu

(Szegedy ve ark., 2017) kendi geliştirdikleri Inception modeline ASA yapısını ekleyerek hibrit bir model oluşturmuşlardır. Oluşturulan hibrit model ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ILSVRC) 2012 sınıflandırma veri setiyle eğitilmiş ve geçmişteki modellere nazaran daha başarılı sonuçlar elde edilmiştir.

(Chen ve ark., 2017) klasik konvolüsyon filtreleri yerine genişletilmiş (atrous) konvolüsyon filtrelerinin kullanımını önermişlerdir. Buradaki amaç, klasik konvolüsyon filtrelerinden sonra görüntü boyutunda meydana gelen azalmanın çıkarılan özellik haritalarında bilgi kaybına neden olmasıdır.

(Badrinarayanan ve ark., 2017) anlamsal piksel bazlı segmentasyon modeli olan SegNet'i önermişlerdir. Önerilen model Şekil 2.6'da görüldüğü gibi kodlayıcı ve kod çözücü olmak üzere iki bölümden oluşmaktadır. Kodlayıcı kısımda konvolüsyon filtreleriyle özellik haritaları çıkarılırken, kod çözücü kısımda dekonvolüsyon filtreleriyle çıkarılan özellik haritalarından segmente edilen görüntüye dönüşüm yapılır.



Şekil 2.6. SegNet yapısı

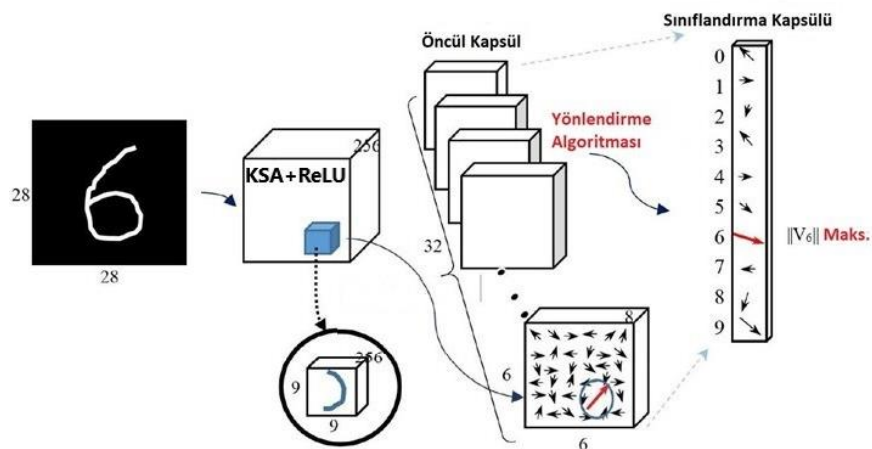
(Chollet, 2017) Inception modelinden farklı olarak derinlemesine ayrılabilir konvolüsyon işlemi kullanarak Xception modelini geliştirmiştir. Farklı veri setleriyle

yapılan sınıflandırma çalışmalarında Inception modeline göre daha başarılı sonuçlar elde edilmiştir.

(Huang ve ark., 2017) girdiye yakın katmanlar ile çıktıya yakın katmanlar arasında daha kısa bağlantılar varsa daha derin ve eğitilmesinin daha verimli olacağını düşünmüşlerdir. Bu amaçla yoğun konvolüsyonel ağları (DenseNet) tanıtmışlardır.

(Howard ve ark., 2017) mobil ve gömülü görüntü uygulamaları için MobileNet ağını geliştirmişlerdir. Bu ağda derinlemesine ayrılabilir konvolüsyon filtreleri mevcuttur. Böylece parametre sayısını önemli ölçüde azaltmayı hedeflemişlerdir. Görüntü sınıflandırma nesne tanımlama gibi problemlerde başvurulan modellerden birisidir.


(Sabour ve ark., 2017) KSA'da havuzlama katmanında meydana gelen veri boyutu azaltma sırasında çıkarılan bazı özelliklerde kayıplar meydana geldiğini iddia etmişler ve bunun çözümü olarak kapsül ağları bilim dünyasına tanıtmışlardır. Kapsül ağlar temel olarak konvolüsyon, öncül kapsül ve sınıflandırma kapsülü katmanlarından oluşmaktadır. Konvolüsyon katmanında KSA'dan aşına olunan konvolüsyon ve aktivasyon fonksiyonundan geçirme işlemleri gerçekleştirilir ve özellik haritaları elde edilir. Öncül kapsül kısmında bir önceki katmanda elde edilen özellik haritaları kapsüller halinde depolanır ve görüntüdeki nesnelerin poz, yükseklik, açı gibi farklı özelliklerini temsil eden kapsüller oluşturulur. Sınıflandırma kapsülünde ise öncül kapsüldeki kapsüllerle giriş görüntüsünün sınıfı tahmin edilmeye çalışılır. Burada doğru sınıfı belirlemek amacıyla yönlendirme algoritmasıyla ağ optimize edilir. Şekil 2.7'de kapsül ağ yapısı sunulmuştur.



Şekil 2.7. Kapsül ağ yapısı

(Zoph ve ark., 2018) veri setine uygun modeli aramak amacıyla NASNet modelini önermişlerdir. Bu yapıda sabit bir modelde veriyi eğitmek yerine veriye uygun parametrelerin seçilip verinin eğitilmesi amaçlanmıştır.

(Zhou ve ark., 2018) U-Net'in geliştirilmiş versiyonu olarak U-Net++'ı önermişlerdir. Şekil 2.8'de U-Net++ yapısı sunulmuştur. Bu modelde U-Net'ten farklı olarak iki alt ağı birbirine bağlayan atlama yolları (Şekil 2.8'de yeşil ve mavi çizgiler) yeniden tasarlanmıştır.



Şekil 2.8. U-Net++ yapısı (Zhou ve ark., 2018)

2.2. MIAS Veri Setiyle İlgili Yapılan Çalışmalar

(Guan ve Loew, 2017) mini-MIAS (The Mammographic Image Analysis Society) ve TMDV (Tarama Mamografisi için Dijital Veritabanı) veri setlerini kullanarak sağlıklı ve kitle bulunan mamografi görüntülerinin sınıflandırmasını yapmışlardır. İlk olarak MIAS veri tabanı üzerinde üç eğitim yöntemi test edilmiştir: 1) Sıfırdan bir KSA eğitildi, 2) Giriş mamogramlarından özellikler çıkarmak için önceden eğitilmiş VGG-16 modeli uygulandı ve bu özellikler bir sinir ağı sınıflandırıcısını eğitmek için kullanıldı, 3) Anormal bölgeleri tespit etmek için önceden eğitilmiş VGG-16 modelinin sondan birkaç katmanındaki ağırlıklar geri yayılma ile güncellendi. Bu çalışmalar sonucunda en iyi sonucu 2 numaralı yöntemin verdiği görülmüş ve bu yöntem TMDV veri setine uygulanmıştır. 10-kat çapraz doğrulama kullanılarak gerçekleştirilen çalışma sonucunda ortalama %90.5 doğruluk oranı elde etmişlerdir.

(Duraisamy ve Emperumal, 2017) MIAS ve MKDD (Meme Kanseri Dijital Deposu) veri setlerini kullanarak sağlıklı ve kitle bulunan mamografi görüntülerinin sınıflandırmasını yapmışlardır. Mamogramların ilk konturunu çıkarmak için Chan-Vese seviye kümesi yöntemi ve memeye özgü kitle ve mikro kalsifikasyon kümelerinin özelliklerini öğrenmek için derin öğrenme konvolüsyon sinir ağı (DÖ-KSA) kullanılmıştır. Sınıflandırma doğruluğunu artırmak ve yanlış pozitifleri azaltmak için iyi bilinen bir tam karmaşık değerli gevşeme ağı sınıflandırıcısı DÖ-KSA ağının son aşamasında kullanılmıştır. Standart kıyaslama meme kanseri veri seti (MIAS ve MKDD) kullanılarak önerilen yöntemin geleneksel yöntemlere göre performansta önemli bir gelişme sergilediğini göstermişlerdir. Elde edilen doğruluk, duyarlılık, özgüllük, eğri altındaki alan (EAA, Area Under Curve) gibi performans ölçütleri sırasıyla %99, %98.75, %100 ve %98.15 olarak elde edilmiştir.

(Sun ve ark., 2019) mini-MIAS ve TMDV veri setlerini kullanarak iyi ve kötü huylu kitle sınıflandırması yapmışlardır. Yapılan çalışmada, farklı mamografi görünümülerinden faydalanılarak oluşturulan bir Çoklu Görünümlü Konvolüsyonel Sinir Ağı (Multi-View Convolutional Neural Networks) yapısı önermişlerdir. TMDV veri seti eğitim için, mini-MIAS veri seti ise test için kullanılmıştır. Çalışma sonucunda MIAS veri seti için %63.06'lık bir doğruluk oranı elde etmişlerdir.

(Kavitha ve ark., 2021) mini-MIAS ve TMDV veri setlerini kullanarak iyi ve kötü huylu kitle sınıflandırması yapmışlardır. Önerdikleri optimal çok seviyeli eşikleme tabanlı segmentasyon modeliyle önce görüntüler üzerinde segmentasyon işlemi gerçekleştirmişlerdir. Sonrasında kapsül ağları kullanarak özellik çıkarımı yapmışlar ve geri yayımlı sinir ağıyla da sınıflandırma işlemi gerçekleştirmişlerdir. Çalışma sonucunda mini-MIAS veri seti üzerinde %98.5 doğruluk, %98.46 duyarlılık, %99.08 kesinlik ve %98.91 F-1 skor elde etmişlerdir.

(Saber ve ark., 2021) MIAS veri seti üzerinde sınıflandırma çalışması gerçekleştirmişlerdir. Yapılan çalışmada, çapraz doğrulama ve 80-20 yöntemine göre veri seti eğitim ve test için ayrılmış sonrasında farklı transfer öğrenmesi modelleriyle (VGG-16, VGG-19, Inception-V3, ResNet-50) sınıflandırılmıştır. Çalışma sonucunda en iyi sonuçlar VGG-16 modeliyle 80-20 yönteminde %98.96 doğruluk, %97.83 duyarlılık, %99.13 özgüllük, %97.35 kesinlik, %97.66 F-skor ve 0.995 EAA olarak elde edilmiştir.

2.3. Polip Veri Setiyle İlgili Yapılan Çalışmalar

(Bardhi ve ark., 2017) polipleri tespit etmek için SegNet tabanlı bir model kullanmışlardır. 3 farklı veri setiyle çalışmalarını gerçekleştirmişlerdir. CVCColon DB, CVC-Clinic DB ve ETIS-Larib Polyp DD veri setleri için doğruluk sonuçlarını sırasıyla %93.7, %95.1 ve %96.7 olarak elde etmişlerdir.

(Brandao ve ark., 2017) kolonoskopi görüntülerinde polip tespiti ve segmentasyonu için Tam Konvolüsyonel Ağı (TKA, Fully Convolutional Network) AlexNet, VGG ve GoogLeNet modelleriyle uyarlamışlardır. ETIS-Larib Polyp DD veri setiyle yapılan çalışma sonucunda en iyi sonuçlar VGG kullanılan modelde sırasıyla %73.6 kesinlik ve %86.3 duyarlılık olarak elde edilmiştir.

(Li ve ark., 2017a) polip segmentasyonu için hibrit bir TKA ve U-Net yapısı önermişlerdir. Çalışmada, CVC-Clinic DB veri seti kullanılmış olup doğruluk, F1-skor, duyarlılık, özgülük değerlerini sırasıyla %96.9, %83, %77.3 ve %99 olarak bulmuşlardır.

(Nguyen ve Lee, 2018) kolonoskopi görüntülerinden polip tespiti üzerine bir çalışma gerçekleştirmişlerdir. Model olarak kodlayıcı-kod çözücü şeklinde modellenmiş bir yapı kullanmışlardır. Eğitim ve doğrulama aşamasında ETIS-Larib Polyp DB veri setini, test aşamasında CVC-Clinic DB polip veri setini kullanmışlardır. Çalışma sonucunda DK ve Jaccard sırasıyla %82.9 ve %84.2 olarak elde edilmiştir.

(Kang ve Gwak, 2019) kolonoskopi görüntülerinde polipleri tanımlamak ve segmentlere ayırmak için en güçlü nesne algılama sinir ağlarından biri olan 'Mask R-CNN'i, ResNet50 ve ResNet101 yapılarıyla birlikte kullanıp iki farklı modelden elde edilen görüntüleri birleştirmişlerdir. Çalışmada CVC-Clinic DB veri seti eğitim kısmında, CVCColon DB ve ETIS-Larib Polyp DD veri setleri de test kısmında kullanılmıştır. En iyi sonuçları CVCColon DB ile yapılan testler için sırasıyla %77.9 kesinlik, %76.2 duyarlılık ve %69.4 Jaccard skoru olarak elde etmişlerdir.

(Banik ve ark., 2020) poliplerin otomatik segmentasyonu için çok ölçekli yama tabanlı bir KSA modeli önermişlerdir. Çalışmada, CVC-Clinic DB veri seti kullanılmış olup Dice Katsayısı (DK, Dice Score Coefficient), kesinlik, duyarlılık skorları sırasıyla %81.3, %80.9 ve %78.6 olarak elde edilmiştir.

2.4. Sürrenal Veri Setiyle İlgili Yapılan Çalışmalar

(Saiprasad ve ark., 2010) BT görüntülerinde adrenalleri segmentlere ayırmak için manuel bir araç geliştirmişlerdir. Ayrıca her adenomun histogramlarını hesaplamışlardır. Çalışma sonucunda sınıflandırma doğruluğu %87, duyarlılık %88, özgüllük %86 elde edilmiştir.

(Saiprasad ve ark., 2013) rasgele orman algoritması ile adrenal bez anormalliğini tespit etmeye çalışmışlardır. Çalışmada BT görüntüleri adrenal bez, sol adrenal bez ve arka plan olarak sınıflandırılmıştır. Sınıflandırma, piksel sınıflandırma yöntemi kullanılarak yapılmıştır. Adrenal bez anormalliği için histogram analizi kullanılmıştır. Sadece 20 BT görüntüsünün kullanıldığı çalışmalarda ortalama duyarlılık ve özgüllük skorları sırasıyla %80 ve %90 olarak elde edilmiştir.

(Tang ve ark., 2014) BT görüntülerinde adrenal tümör tiplerinden biri olan feokromositoma tümörünün segmentasyonunu gerçekleştirmişlerdir. Çalışmalarında sadece 10 adet 3B BT görüntüsü kullanmışlardır. Çalışma sonucunda arteriyel fazda %92.7 DK, venöz fazda %92.9 DK elde edilmiştir.

(Chai ve ark., 2015) BT görüntülerinde adrenal tümör tespiti ve sınıflandırması gerçekleştirilmiştir. Bölütleme algoritması, sınıflandırma algoritması ve özellik çıkarımından oluşan bir BDT sistemi önermişlerdir. Çalışma sonucunda 436 BT görüntüsünde %90 doğruluk elde edilmiştir.

(Koyuncu ve Ceylan, 2017) dinamik BT görüntülerinde adrenal lezyonlar içeren bir İlgi Alanı (İA-ROI) seçmişler, ardından bunu Gri Düzeyli Eş Oluşum Matrisi (GDEOM, Gray Level Co-occurrence Matrix) ve ikincil sıra istatistiklerini kullanarak özellik çıkarımı ve sınıflandırma izlemiştir. Sınıflandırma aşamasında Yapay Sinir Ağları (YSA) ve yeni bir YSA tabanlı teknik (Sınırlı PSO-ANN) kullanılmış ve sınıflandırma performansı üç ayrı metrik ile değerlendirilmiştir. Doğruluk %78.95, EAA %84.29 ve Ortalama Kare Hatası (OKH, Mean Squared Error) %0.1592 olarak elde edilmiştir.

(Li ve ark., 2017b) BT görüntülerinden iyi huylu ve kötü huylu lezyonların özelliklerini çıkarmak için GDEOM yöntemini kullanmışlardır. Lezyon tiplerinin sınıflandırma tahmini için Bayes olasılık modeli kullanılmıştır. Çalışmada, 121 iyi huylu ve 109 kötü huylu lezyon olmak üzere toplam 230 lezyon kullanılmış ve önerilen yöntem ile sınıflandırma doğruluğu %80 olarak elde edilmiştir.

(Bi ve ark., 2017) düşük kontrastlı BT görüntülerinde adrenal tümörlerin saptanması için TKA kullanmışlardır. Ayrıca, farklı ölçeklerde tümör sınırlarını

iyileştirmek için Süper Piksel Tabanlı Rastgele Yürüyüş (SPTRY, Superpixel Based Random Walk) yaklaşımıyla çok ölçekli bir entegrasyon önermişlerdir. Çalışmada 38 düşük kontrastlı BT görüntüsü kullanılmıştır. Çalışma sonucunda kesinlik, duyarlılık ve F1-skor metrikleri sırasıyla %69.82, %76.29 ve %72.91 olarak elde edilmiştir.

(Romeo ve ark., 2018) 60 MR görüntüsü kullanarak adrenal tümör sınıflandırması gerçekleştirmişlerdir. Adrenal tümörler manuel olarak segmentlere ayrılmış ve farklı özellik seçim yöntemleri kullanılarak sınıflandırılmıştır. Çalışma sonucunda J48 sınıflandırıcı ile %80 sınıflandırma doğruluğu elde edilmiştir.

(Foti ve ark., 2018) çeşitli ara ve gecikmeli faz kombinasyonlarının doğruluğunun teşhisini gerçekleştirmişlerdir. Çalışmada 82 adenom görüntüsü ve 47 adenom olmayan görüntü kullanılmışlardır. İstatistiksel analiz kullanarak sınıflandırma yapmışlar ve sınıflandırma doğruluğu %97.6 olarak elde edilmiştir.

(Koyuncu ve ark., 2018) BT görüntülerinde adrenal tümör segmentasyonu için bir Adrenal Tümör Segmentasyonu (ATUS) şeması önermişlerdir. ATUS, kontrast sınırlı uyarlanabilir histogram eşitleme, dört ağaç ayrıştırmasına dayalı bölme ve birleştirme, ortalama kaydırma segmentasyonu, büyük gri seviye ayırıcı ve bölge büyütme dahil olmak üzere bir dizi görüntü yöntemi içerir. Çalışmada sadece 32 görüntü kullanılmış ve DK %83.06, Jaccard %71.44, duyarlılık %86.44, özgüllük %99.66, doğruluk %99.43 ve Yapısal Benzerlik İndeksi (YBİ, Structural Similarity Index Measure) %98.51 olarak bulunmuştur.

(Barstuğan ve ark., 2018) MR görüntülerinde adrenal tümörleri segmentlere ayırmak için bir BDT sistemi önermişlerdir. Önerilen hibrit yöntem, aktif kontur, uyarlanabilir eşikleme, kontrast sınırlı uyarlanabilir histogram eşitleme, görüntü erozyonu ve bölge büyütme gibi birçok görüntü işleme yöntemini içermektedir. Çalışma 113 MR görüntüsü üzerinde gerçekleştirilmiş ve duyarlılık, özgüllük, doğruluk, kesinlik, DK, Jaccard ve YBİ sırasıyla %60.07, %99.99, %97.69, %83.68, %63.14, %51.14 ve %97.07 olarak elde edilmiştir.

(Koyuncu ve ark., 2019) 5 farklı teknik kullanarak 8 farklı alt türden oluşan bir veri setinden adrenal tümörlerin ikili karakterizasyonunu gerçekleştirmişlerdir. Çalışma sonucunda %80.7 doğruluk, %75 duyarlılık, %82.22 özgüllük ve %78.61 EAA tespit etmişlerdir.

(Zhao ve ark., 2019) 3B BT anjiyografi dilimlerinden adrenal tümör damarlarını segmentlere ayırmışlardır. Çalışmada bir 3B U-Net modeli oluşturmuşlar ve sadece 49 adet 3B BT görüntüsü kullanmışlardır. En iyi sonuçlar, DK için %94.69 ve Birleşim

Üzerinde Ortalama Kesişim (BÜOK, Mean Intersection over Union) için %90.22 değerlerine ulaşmışlardır.

(Barstugan ve ark., 2019) adrenal tümörleri T1 ve T2 ağırlıklı MR görüntülerinde sınıflandırmışlardır. Sınıflandırma öncesinde farklı öznelik çıkarma ve filtreleme yöntemleri kullanılmış, sınıflandırma aşamasında Destek Vektör Makinaları (DVM, Support Vector Machine) kullanılmıştır. Çalışma sonucunda T1 ağırlıklı MR görüntüler için duyarlılık, özgüllük ve doğruluk sırasıyla %99.17, %99.13 ve %99.17 olarak bulunmuştur.

(Elmohr ve ark., 2019) 25 adrenal adenom ve 29 adrenal karsinom içeren BT görüntülerinde sınıflandırma çalışması gerçekleştirmişlerdir. Sınıflandırma için lojistik regresyon ve rasgele orman algoritmalarını kullanmışlardır. Çalışmada en iyi sonuçlar lojistik regresyon kullanıldığında doğruluk, özgüllük, duyarlılık ve EAA skorları sırasıyla %82, %83, %81 ve %89 olarak elde edilmiştir.

(Barstugan ve ark., 2020) 112 iyi huylu adrenal tümör ve 10 kötü huylu adrenal tümörden oluşan bir veri seti ile sınıflandırma gerçekleştirmişlerdir. Adrenal tümörlerin en etkili özelliklerini ortaya çıkarmak için gri seviye eş-oluşum matrisi (GSEOM, Gray-Level Co-occurrence Matrix), gri seviye çalışma uzunluğu matrisi (GŞÇUM, Gray-Level Run-Length Matrix) ve ayrık dalgacık dönüşümü (ADD, Discrete Wavelet Transform) gibi farklı yöntemler uygulamışlardır. Çalışma sonucunda sırasıyla %99.17, %90, %98.4 duyarlılık, özgüllük ve doğruluk elde etmişlerdir.

(Moawad ve ark., 2021) özellik çıkarma için birinci seviye, doku ve dalgacık özellik çıkarma yöntemleri kullanarak iyi huylu/kötü huylu adrenal lezyon sınıflandırması çalışmışlardır. Çalışmalarında, 21 iyi huylu, 19 kötü huylu adrenal lezyon bulunan BT görüntüleri üzerinde özellik çıkarımı ve rasgele orman algoritmasıyla sınıflandırma işlemini gerçekleştirmişlerdir. Sonuçta özgüllük, duyarlılık ve EAA skorları sırasıyla %71.4, %84.2 ve %85 olarak elde edilmiştir.

(Bi ve ark., 2022) 229 BT görüntüsünden (54 adrenokortikal karsinom, 35 fonksiyonel olmayan adrenal adenom, 33 adrenal miyelolipom, 58 ganglionörom ve 49 feokromositoma) oluşan bir veri seti kullanarak çok sınıflı sınıflandırma çalışması gerçekleştirmişlerdir. Çalışmaya özgü derin çok-ölçekli benzerlik ağını (DÇBA, Deep Multi-Scale Resemblance Network) önermişler ve beş kat çapraz doğrulama kullanmışlardır. Çalışma sonucunda; doğruluk, özgüllük, duyarlılık, kesinlik ve F1-skoru sırasıyla %89.5, %97.3, %90.7, %89.9 ve %89.9 olarak hesaplanmıştır.

(Kusunoki ve ark., 2022) 107 BT görüntüsünden (83 adrenal adenom, 24 adrenal adenom olmayan) sınıflandırma çalışması yapmışlardır. Kontrast olmayan, erken faz, gecikmiş faz gibi farklı görüntü modelleriyle derin konvolüsyon sinir ağı (DKSA) kullanmışlar ve sonuçları karşılaştırmışlardır. Elde edilen en iyi sonuçlar özgüllük, duyarlılık ve EEA skoru sırasıyla %100, %90 ve %99 idi.

(Liu ve ark., 2022) 280 BT görüntüsünden (188'i lipidden fakir adenom ve 92'si subklinik feokromositoma) oluşan bir veri seti ile iki yapıyı ayırt etmek için çalışmalar yürütmüşlerdir. Lojistik regresyon, destek vektör makinesi ve rastgele ormandan oluşan bir puanlama sistemi kullanarak görüntüleri sınıflandırmışlardır. Çalışmada en iyi skorlar lojistik regresyonla yapılan çalışmalarda doğruluk, duyarlılık, özgüllük ve EAA için sırasıyla %86.4, %81.5, %91 ve %91.7 olarak elde edilmiştir.

2.5. Pnömoni Veri Setiyle İlgili Yapılan Çalışmalar

(Kermany ve ark., 2018) IMAGENET üzerinde eğitilmiş ağırlıkları kullanarak X-ışını (X-ray) görüntülerinde sınıflandırma için bir KSA modeli geliştirmişlerdir. Normal ve pnömoni sınıflandırması için %93.2 duyarlılık, %90.1 özgüllük, %96.8 EAA ile %92.8 doğruluk elde etmişlerdir.

(Rajaraman ve ark., 2018) özelleştirilmiş bir KSA ve VGG16 modelini kullanarak üç farklı sınıflandırma çalışması (Normal-Pnömoni, Bakteriyel Pnömoni-Viral pnömoni ve Normal-Bakteriyel pnömoni-Viral Pnömoni) yürütmüşlerdir. Çalışma sonucunda, Normal-Pnömoni sınıflandırması için en iyi skorlar %96.2 doğruluk, %99.3 EAA, %97.7 kesinlik, %96.2 duyarlılık ve %97 F1-skor olarak elde edilmiştir.

(Ayan ve Ünver, 2019) VGG16 ve Xception ağırlarını karşılaştırarak sınıflandırma çalışmaları yapmışlardır. Çalışma sonucunda VGG16 ağı daha başarılı sonuçlar vermiştir. Bu ağ için değerlendirme sonuçları %87 doğruluk, %82 duyarlılık, %91 özgüllük olarak elde edilmiştir.

(Saraiva ve ark., 2019) pnömoni içeren X-ışını görüntülerini sınıflandırmak için KSA'yı kullanmışlardır. Çalışmalarında 5 kat çapraz doğrulama kullanmışlardır. Çalışma sonucunda test görüntülerinde ortalama %95.3 doğruluk elde etmişlerdir.

(Stephen ve ark., 2019) göğüs röntgeni görüntülerinden sağlıklı ve pnömoni sınıflandırması yapmışlardır. Çalışmada ön işleme ve veri artırma yöntemleri kullanmışlar ve model olarak sıfırdan bir KSA mimarisi önermişlerdir. Farklı görüntü

boyutları ile yapılan çalışmalar sonucunda en iyi sonuçları eğitimde %95.31 ve validasyonda %93.73 doğruluk tespit etmişlerdir.

(Gülgün ve Hamza, 2020) KSA, veri büyütme ve transfer öğrenimi kullanarak X-ışını görüntülerinde pnömoni ve sağlıklı ayrımı yapmışlardır. Çalışma sonucunda test görüntülerinde %93.4 doğruluk elde etmişlerdir.

(Liang ve Zheng, 2020) KSA yapısında genişletilmiş konvolüsyon ve transfer öğrenmeyi kullanmışlardır. Transfer öğrenimi için klasik modeller (VGG16, Inception, DenseNet vb.) yerine tıbbi görüntülerle eğitilmiş bir ağ kullanmışlardır. Çalışma sonucunda %90.5 doğruluk, %89.1 kesinlik, %96.7 duyarlılık, %92.7 F1-skoru ve %95.3 EAA skoru elde etmişlerdir.

(Chouhan ve ark., 2020) önceden ImageNet veri setinde eğitilmiş beş farklı modeli kullanarak oluşturulan bir bileşik model ile röntgen görüntülerinden sınıflandırma işlemi gerçekleştirilmiştir. Çalışma sonucunda test görüntülerinde %96.39 doğruluk, %99.34 EAA, %93.28 kesinlik ve %99.62 duyarlılık elde edilmiştir.

(Çınar ve ark., 2021) geliştirilen ResNet50 modeli ile röntgen görüntüleri üzerinde pnömoni ve sağlıklı görüntülerin sınıflandırmasını yapmışlardır. Geliştirilen model, farklı transfer öğrenme modelleri ve literatür ile karşılaştırılmıştır. Çalışma sonucunda %97.12 doğruluk, %95.78 duyarlılık, %97.69 özgüllük ve %94.51 F1-skoru elde edilmiştir.

(Manickam ve ark., 2021) farklı transfer öğrenme yapıları, optimize ediciler ve yığın boyutları kullanarak kapsamlı bir sınıflandırma analizi gerçekleştirmişlerdir. Çalışma sonucunda önerilen ResNet50 yapısı ile %93.06 doğruluk, %88.97 kesinlik, %96.78 duyarlılık ve %92.71 F1-skor elde edilmiştir.

3. MATERYAL VE YÖNTEM


3.1. Materyal

Tez çalışması kapsamında önerilen derin öğrenme modellerinin test edilmesi amacıyla dört farklı medikal görüntü veri seti kullanılmıştır. Bu veri setleri sırasıyla mamogram görüntü veri seti, abdomen görüntü veri seti, polip görüntü veri seti ve pnömoni (zatürre) veri setidir. Her bir veri setine ait detaylı bilgi ilerleyen bölümlerde verilmiştir.

3.1.1. Mamogram görüntü veri seti

Mamografi meme kanseri teşhisi için kullanılan en yaygın ve kolay yöntemdir. Geleneksel BDT sistemleri, radyologlar tarafından mamogram görüntülerinin yorumlanmasına yardım etmek amacıyla kullanılır. Ancak bu sistemler genellikle görüntüde normal dokudan farklı olan kısımların elle işaretlenmesi temeline dayanır. Radyologlar bu bulgulara bakarak işaretlenen kısmın klinik öneme sahip olup olmadığına karar verirler.

Tez çalışması kapsamında mini-MIAS (The Mammographic Image Analysis Society) mamografi görüntüleri veri seti kullanılmıştır (Suckling, 1994). Kullanılan veri seti 64 adet iyi huylu ve 52 adet kötü huylu olmak üzere toplamda 116 adet kitle bulunan mamogram görüntülerinden oluşmaktadır. Her bir görüntü 1024x1024 piksel boyutlarındadır. Bu görüntülere iki farklı ön işlem uygulanmış ve böylece iki farklı veri seti elde edilmiştir. İlk ön işlemede görüntüdeki kullanılmayan harf, rakam, sayı gibi sınıflandırmada bilgi içermeyen kısımlar görüntüden temizlenmiştir. Şekil 3.1 (a)'da verilen orijinal görüntü bu temizleme adımıyla Şekil 3.1 (b)'deki halini almıştır ve böylece temizlenmiş görüntülerden oluşan veri seti elde edilmiştir. İkinci ön işleme adımında ise görüntüde sadece memenin bulunduğu kısım alınarak eğitim esnasında gereksiz piksellerin işlenmesinin önüne geçilmiştir. Şekil 3.1 (a)'da verilen görüntüye ikinci ön işleme adımı uygulandığında Şekil 3.1 (c)'deki görüntü elde edilmiş ve böylece kesilmiş görüntülerden oluşan veri seti oluşturulmuştur. Tez çalışmasında kullanılan ağlar temizlenmiş ve kesilmiş (kırpılmış) veri setleriyle ayrı ayrı eğitilmiş ve test edilmiştir.




Şekil 3.1. MIAS veri seti a) Orijinal MIAS görüntüsü (1024×1024)
b) Temizlenmiş MIAS görüntüsü (1024×1024) c) Kesilmiş MIAS görüntüsü (446×615)

3.1.2. Polip görüntü veri seti

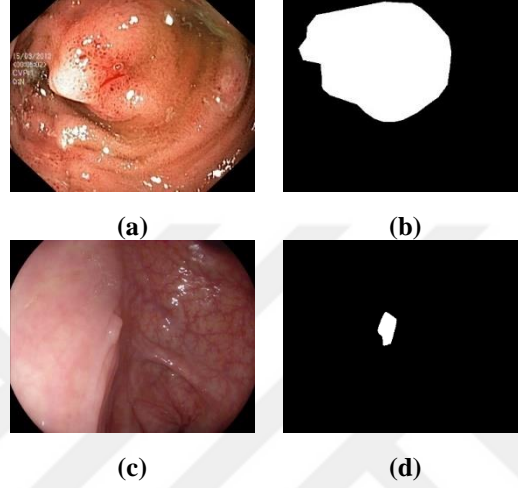
Polipler, kolon, burun, rahim ve mide dahil olmak üzere vücudun çeşitli bölgelerinde oluşabilen anormal doku büyümeleridir. Bu büyümeler iyi huylu veya kötü huylu olabilir. En yaygın polip türü, kalın bağırsağın iç astarında oluşan büyümeler olan kolon polipleridir. Kolon poliplerinin çoğu iyi huyludur, ancak bazıları zamanla kolon kanserine dönüşebilir. Bu nedenle, herhangi bir polipi kansere dönüşmeden önce tespit etmek ve çıkarmak için düzenli kolonoskopi yaptırmak önemlidir (Van Rijn ve ark., 2006).

Tez çalışması kapsamında çalışmalarda temel polip veri seti olarak MICCAI 2015 polip algılama yarışmasında kullanılan CVC-ClinicDB (Bernal ve ark., 2015; Bernal ve ark., 2017) veri seti kullanılmıştır. Veri setinde 612 adet görüntü bulunmakta ve görüntüler 384×288 boyutlarındadır. Hedef görüntüler, polipler beyaz ve arka plan siyah olacak şekilde ikili formatta oluşturulmuştur. Çalışmada kullanılan görüntülerin ve maskelerin bir örneği Şekil 3.2'de verilmiştir.



Şekil 3.2. CVC-ClinicDB veri seti örnek görüntüler a) Kolonoskopi görüntüsü b) Polipe karşılık gelen maske

CVC-ClinicDB veri seti üzerinde gerçekleştirilen çalışmalarda optimum sonuçları veren segmentasyon modelini test etmek amacıyla Kvasir-Seg (Jha ve ark., 2020) ve ETIS-Larib (Silva ve ark., 2014) veri setlerinden yararlanılmıştır. Bu veri setlerinden Kvasir-Seg içerisinde 622x529 boyutunda 1000 tane görüntü ve maske mevcuttur. ETIS-Larib veri seti ise 1225x966 boyutunda 196 tane görüntü ve maskeye sahiptir. Şekil 3.3'te bu veri setlerine ait görüntüler ve poliplere karşılık gelen maskeler yer almaktadır.




Şekil 3.3. a) Kvasir-Seg kolonoskopi görüntüsü b) Kvasir-Seg kolonoskopi görüntüsünde polipe karşılık gelen maske c) ETIS-Larib kolonoskopi görüntüsü d) ETIS-Larib kolonoskopi görüntüsünde polipe karşılık gelen maske

3.1.3. Abdomen görüntü veri seti

Adrenal bezler böbreklerin üzerinde yer alır ve çeşitli vücut fonksiyonlarını düzenleyen hormonların üretilmesinden sorumludur. Adrenal lezyonlar, adrenal bezlerin birinde veya her ikisinde meydana gelen anormal büyümeleri veya kitleleri ifade eder. Adrenal lezyonların semptomları, lezyonun türüne, boyutuna ve ayrıca hormon üretip üretmediğine bağlı olarak değişebilir. Adrenal lezyonların bazı yaygın semptomları arasında karın ağrısı, sırt ağrısı, kilo kaybı ve yüksek tansiyon yer alır. Adrenal lezyonların teşhisi tipik olarak BT, MR veya PET taramaları gibi görüntüleme testlerinin yanı sıra hormon seviyelerini kontrol etmek için kan testlerini içerir. Adrenal lezyonların tedavisi, lezyonun türüne, boyutuna ve semptomların varlığına bağlıdır. Tedavi seçenekleri arasında lezyonu çıkarmak için ameliyat, hormon üretimini kontrol etmek için ilaç tedavisi veya lezyon küçükse ve semptomlara neden olmuyorsa gözlem ve izleme yer alabilir (Mendiratta-Lala ve ark., 2017).

Tez çalışması kapsamında kullanılan abdomen görüntü veri seti Selçuk Üniversitesi Tıp Fakültesi Radyoloji Anabilim dalından alınan T1 ve T2 ağırlıklı 112 iyi huylu ve 10 kötü huylu lezyon içeren MR abdominal görüntülerinden oluşmaktadır. Görüntüler, SIEMENS AREA 1.5T 2013 cihazı ile DICOM formatında 800 x 584 boyutlarında, 8-bit derinlik ve 96 DPI çözünürlükte elde edilmiştir. Görüntüler JPEG formatına dönüştürülmüştür. Veri setindeki tüm görüntüler deneyimli bir radyolog tarafından incelenerek sürrenal bezler etiketlenmiştir. Hedef görüntüler, tümörler beyaz ve arka plan siyah olacak şekilde ikili formatta oluşturulmuştur. İş yükünü azaltmak, gereksiz parçaları çıkarmak ve eğitimi hızlandırmak için sürrenal görüntülerde sadece adrenal tümör bulunan bölgeler bir başka deyişle ilgi alanı (İA) çıkarılmıştır. Çalışmada kullanılan T1 ve T2 ağırlıklı abdomen MR görüntüleri sırasıyla Şekil 3.4 (a) ve Şekil 3.4 (b)'de verilmiştir. Bu görüntülerde adrenal tümöre karşılık gelen maske görüntüsü de Şekil 3.4 (c)'de görülmektedir.



Şekil 3.4. Abdomen veri seti a) T1 ağırlıklı görüntü b) T2 ağırlıklı görüntü c) Adrenal tümöre karşılık gelen görüntü

3.1.4. Pnömoni (Zatürre) görüntü veri seti

Pnömoni, bakteriyel, viral veya mantar enfeksiyonunun neden olduğu akciğerlerin iltihaplı bir durumudur. Bir veya her iki akciğeri etkileyebilir ve enfeksiyona neden olan organizmanın türüne ve etkilenen kişinin sağlık durumuna bağlı olarak hafif veya şiddetli bir hastalık olabilir. Zatürre belirtileri arasında öksürük, ateş, göğüs ağrısı, nefes darlığı, yorgunluk nadiren terleme ve titreme yer alır. Bebekler ve küçük çocuklarda karın ağrısı, kusma ve ishal de görülebilir. Bu hastalığa yakalanan çoğu kişi uygun tedavi ile tamamen iyileşir. Ancak bazı durumlarda, özellikle yaşlı yetişkinler, bebekler ve bağışıklık sistemi zayıf olan kişilerde zatürre hayatı tehdit edebilir (Gereige ve Laufer, 2013).

Tez çalışması kapsamında zatürre tespiti için göğüs röntgeni veri seti, Guangzhou Kadın ve Çocuk Tıp Merkezi'nde bir ila beş yaşındaki pediatrik hastalardan oluşan retrospektif bir gruptan seçilmiştir (Kermany ve ark., 2018). Veri seti, 1583'ü normal ve

4273'ü zatürre olmak üzere toplam 5856 akciğer röntgeni görüntüsünden oluşmaktadır. Şekil 3.5'te veri setinde kullanılan görsellere bir örnek verilmiştir.



Şekil 3.5. Çalışmada kullanılan görüntüler a) Sağlıklı Görüntü b) Pnömoni Görüntü

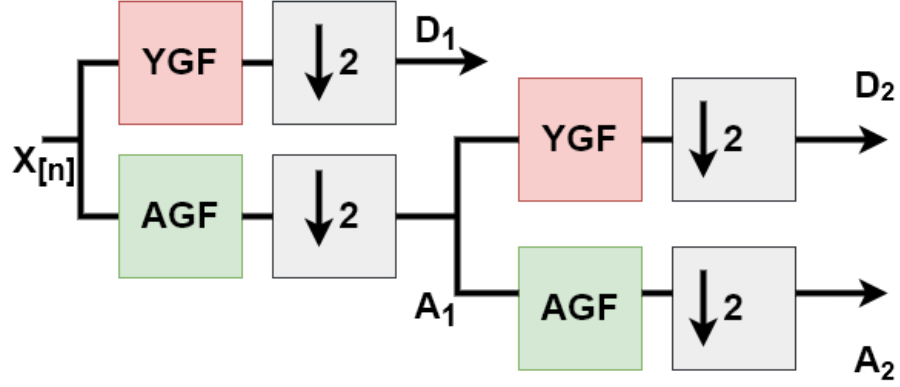
3.2. Veri Setleri Üzerinde Kullanılan Ön İşlemler

Bu bölümde, tez çalışmasında kullanılan veri setlerindeki görüntülere sınıflandırma ve segmentasyon sonuçlarını iyileştirmek amacıyla uygulanan ön işlemlere yer verilmiştir. Bu amaçla, görüntülere uygulanan ayırık dalgacık dönüşümü (ADD), ayırık kosinüs dönüşümü (AKD), kontrast sınırlı uyarlamalı histogram eşitleme (KSUHE) ve füzyon teknikleri alt başlıklar halinde incelenecektir.

3.2.1. Ayırık dalgacık dönüşümü (ADD)

Ayrık Dalgacık Dönüşümü 'nü (ADD) uygulamak için etkili bir yöntem, 1988'de Mallat tarafından filtreler kullanılarak geliştirilmiştir (Mallat, 1988). Bu yöntemde, sinyal (x) eş zamanlı olarak alçak geçiren (AGF) ve yüksek geçiren (YGF) filtrelerden geçirilir. AGF çıkışı sinyal hakkında yaklaşık bilgi verirken, YGF çıkışı ayrıntılı bilgi verir. Aşağı örnekleme ile filtrelerden çıkan sinyalin örnek sayısı yarıya indirilir. Sonuç, giriş sinyalinin yarısı ile düşük frekanslı (A) ve yüksek frekanslı (D) örneklerdir.

Filtreleme ve alt örnekleme işlemi, yaklaşık bilgi veren AGF'nin çıkışında sırayla devam ettirilirse, sinyalin anlamlı olan düşük frekanslı bileşenlerinin daha ayrıntılı bir analizi yapılır. Bu işleme Çoklu Çözünürlük Analizi denir. Bu çalışmada 2 seviyeli ADD kullanılmış ve Şekil 3.6'da 2 seviyeli ADD diyagramı gösterilmektedir.



Şekil 3.6. 2-seviyeli ayrık dalgacık dönüşümü

3.2.2. Ayrık kosinüs dönüşümü (AKD)

Ayrık Kosinüs Dönüşümü (AKD), bir sinyali veya veri dizisini zaman alanından frekans alanına dönüştürmek için sinyal işleme ve veri sıkıştırma için kullanılan matematiksel bir tekniktir. Görüntü ve video sıkıştırma, konuşma tanıma ve ses işleme gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır (Solomon ve Breckon, 2011).

AKD ters çevrilebilir bir doğrusal dönüşümdür, yani orijinal sinyal dönüştürülmüş katsayılarından yeniden yapılandırılabilir. AKD, her bir fonksiyonun sinyalin farklı bir frekans bileşenini temsil ettiği bir dizi ortogonal kosinüs fonksiyonu kullanılarak hesaplanır (Ahmed ve ark., 1974). Denklem 3.1’de AKD’nin matematiksel formülüne, Denklem 3.2 ve 3.3’te de AKD formülünde kullanılan parametrelerin matematiksel ifadelerine yer verilmiştir. Denklemlerde I giriş görüntüsünü, U çıkış görüntüsü, M satır sayısını, N sütun sayısını, p ve q ise çıkış görüntüsünün satır ve sütunlarını temsil etmektedirler.

$$U_{pq} = a_p a_q \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I_{mn} \cos \frac{\pi(2m+1)p}{2M} \cos \frac{\pi(2n+1)q}{2N}, \quad \begin{cases} 0 \leq p \leq M-1 \\ 0 \leq q \leq N-1 \end{cases} \quad (3.1)$$

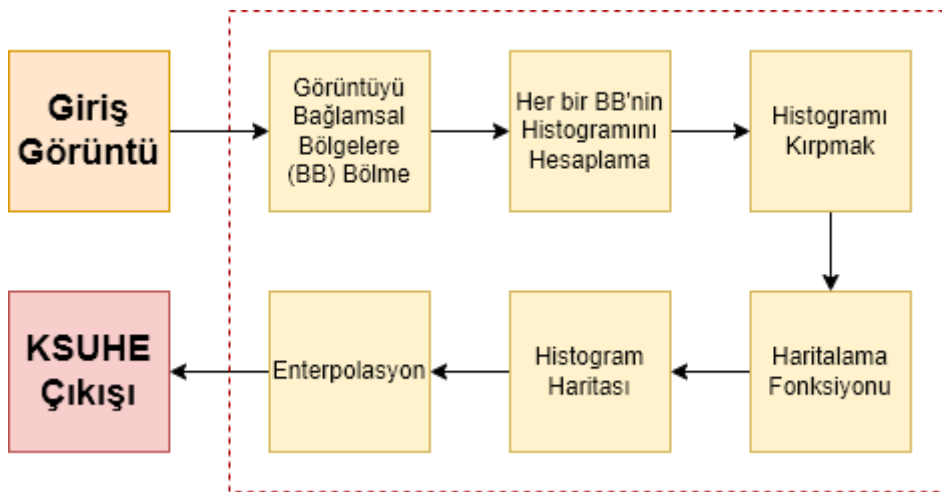
$$a_p = \begin{cases} \frac{1}{\sqrt{M}}, p = 0 \\ \sqrt{\frac{2}{M}}, 1 \leq p \leq M-1 \end{cases} \quad (3.2)$$

$$a_q = \begin{cases} \frac{1}{\sqrt{N}}, q = 0 \\ \sqrt{\frac{2}{N}}, 1 \leq q \leq N-1 \end{cases} \quad (3.3)$$

3.2.3. Kontrast sınırlı uyarlamalı histogram eşitleme (KSUHE)

Görüntü iyileştirmede sıklıkla kullanılan histogram eşitlemede tüm görüntü histogramı ile yoğunluk dinamik aralığı genişletilerek görüntü kalitesi iyileştirilebilir. Histogram eşitlemede görüntünün yoğunluk dağılımı normalize edilerek düzgün bir yoğunluk dağılımı ile sonuç görüntü elde edilir ve böylece iyileştirme işlemi gerçekleştirilir. Ancak, histogram eşitleme tüm görüntünün yoğunluk dağılımını kullandığından, ortalama yoğunluk orta olarak ayarlandığında bu, bazı görüntülerde soluk bir etkiye neden olabilir. Dar bir bölgede kalabalık yoğunluk dağılımına sahip görüntülerde ise çok sayıda gürültü pikselinin oluşmasına neden olabilir. Bu sorunları çözmek için yerel histogram eşitleme teknikleri geliştirilmiştir (Yoon ve ark., 2009).

Uyarlamalı histogram eşitleme, değiştirilmiş bir histogram eşitleme işlemidir ve yerel veriler üzerinde optimizasyon gerçekleştirir. Buradaki ana fikir, görüntünün ızgara şeklinde dikdörtgen bölgelere bölünmesi ve her bölgeye standart histogram eşitlemesinin uygulanmasıdır. Optimum bölge boyutları ve sayısı görüntüye göre değişir. Görüntü alt bölgelere ayrıldıktan ve her bölgeye histogram eşitleme uygulandıktan sonra, daha iyi bir tam görüntü elde etmek için alt bölgeler çift doğrusal enterpolasyon yöntemiyle birleştirilir (Teo, 2003). Ancak, uyarlamalı histogram eşitlemede gürültü sorunu ortaya çıkmaktadır. Bunu önlemek için homojen bölgelerde kontrast artışının sınırlandırılması gerekmektedir ve bu amaçla KSUHE yöntemi geliştirilmiştir. Şekil 3.7'de KSUHE yönteminin tüm süreçlerinin blok diyagramı verilmiştir.



Şekil 3.7. KSUHE Akış Şeması

3.2.4. Görüntü füzyonu

Görüntü füzyonu, aynı sahneye ait birden fazla görüntünün birleştirilerek, her bir görüntüden daha fazla bilgi içeren tek bir görüntü oluşturulması işlemidir. Görüntü füzyonu uzaktan algılama, tıbbi görüntüleme ve bilgisayarla görme gibi çeşitli alanlarda yaygın olarak kullanılan bir tekniktir (Gonzalez, 2008).

Maksimum ve ortalama görüntü füzyonu, birden fazla görüntüyü birleştirmek için kullanılan iki popüler yöntemdir. Maksimum görüntü füzyonunda, giriş görüntülerindeki karşılık gelen piksellerin maksimum değeri birleştirilmiş görüntüyü oluşturmak için kullanılır. Bu yöntem, ilgilenilen nesnelere yüksek kontrasta sahip olduğu ve giriş görüntülerinin yalnızca birinde veya birkaçında bulunduğu durumlarda kullanışlıdır. Ancak bu yöntem, ilgilenilen nesnelere bulunmadığı bölgelerde bilgi kaybına neden olabileceğinden tüm uygulamalar için uygun olmayabilir.

Öte yandan ortalama görüntü füzyonu, birleştirilmiş görüntüyü oluşturmak için giriş görüntülerindeki karşılık gelen piksellerin ortalama değerinin alınmasını içerir. Bu yöntem, ilgilenilen nesnelere tüm giriş görüntülerinde mevcut olduğunda ve benzer yoğunluk değerlerine sahip olduğunda kullanışlıdır. Ortalama görüntü füzyonu, maksimum görüntü füzyonundan daha iyi genel görüntü kalitesine sahip birleştirilmiş görüntü ile sonuçlanabilir. Ancak, giriş görüntüleri arasında ilgilenilen nesnelere yoğunluk değerlerinde büyük farklılıklar olduğu durumlarda etkili olmayabilir.

3.3. Metotlar

Bu kısımda tez çalışması kapsamında kullanılan ve geliştirilen derin öğrenme yöntemleri ele alınmıştır. Bu kapsamda KSA, U-Net, modifiye edilmiş U-Net, kapsül ağlar ve önerilen kapsül ağ yapısı detaylı bir şekilde bölümler halinde incelenmiştir.

3.3.1. Konvolüsyonel sinir ağları (KSA)

Konvolüsyonel sinir ağları (KSA), özellikle bilgisayar görüşü alanında başarılı olmuş bir derin sinir ağı modelidir. KSA'nın geçmişi, 1960'lar ve 1970'lerde yapay sinir ağları ve görüntü işleme üzerine yapılan erken çalışmalara kadar gitmektedir; ancak bugün bildiğimiz şekliyle KSA'ların gelişimi genellikle Yann LeCun ve meslektaşlarının


1980'ler ve 1990'lardaki çalışmalarına atfedilir (LeCun ve ark., 1989; LeCun ve ark., 1995).

LeCun ve ekibi, el yazısı rakam tanıma için özel olarak tasarlanmış LeNet-5 adlı bir KSA geliştirdi (LeCun ve ark., 1995). Bu ağ birkaç konvolüsyon katmanı, ardından alt örnekleme, tam bağlı katmanlardan oluşmakta ve geri yayılım algoritması kullanılarak eğitilmekteydi. LeNet-5, el yazısı rakamlardan oluşan MNIST veri kümesinde en iyi (state-of-the-art) performans elde ederek bilgisayar görüşü alanında bir çığır açarak KSA'ların daha da geliştirilmesinin yolunu açtı. Takip eden yıllarda, KSA'lar, yüz algılama, nesne tanıma ve sahne anlama dahil olmak üzere çok çeşitli görüntü tanıma görevlerine başarıyla uygulandı.

KSA'ların tarihinde dikkate değer bir diğer dönüm noktası, 2012'deki ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) idi. Bu yarışmada, araştırmacılardan 1.000 farklı kategoriye sahip büyük ölçekli bir görüntü veri kümesini yüksek doğrulukla sınıflandırabilecek derin sinir ağları geliştirmeleri istendi. Alex Krizhevsky liderliğindeki bir ekip tarafından geliştirilen AlexNet adlı derin bir KSA modeli %15,3'lük ilk-5 hata oranına ulaştı ve ikinciyi büyük bir farkla geride bıraktı (Krizhevsky ve ark., 2012). İlk-5 hata oranı, doğru etiketin tahmin edilen ilk 5 etiketten biri olmadığı test görüntülerinin yüzdesi olarak tanımlanmaktadır.

AlexNet'in bu başarısından beri KSA'lar, artık bağlantılar, yığın normalleştirme ve dikkat mekanizmaları gibi performanslarını iyileştirmek için yeni mimariler ve teknikler geliştirerek gelişmeye ve giderek daha karmaşık hale gelmeye devam etti. Günümüzde KSA'lar, tıbbi görüntüleme, otonom araçlar ve doğal dil işleme dahil olmak üzere çeşitli uygulamalarda yaygın olarak kullanılmaktadır.

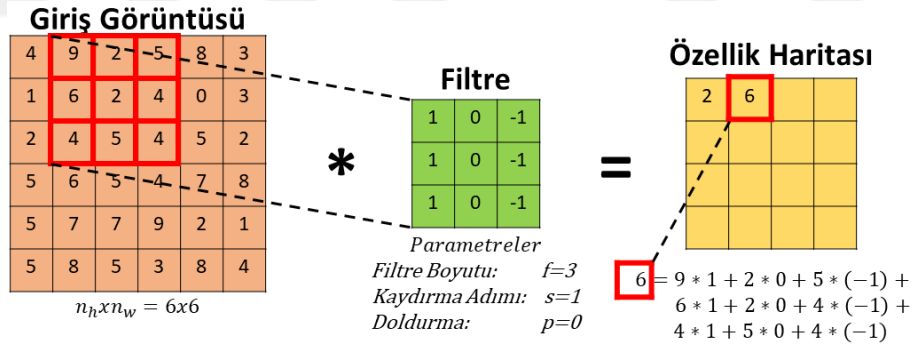
KSA temel olarak adını veren konvolüsyon katmanı, aktivasyon fonksiyonu, havuzlama katmanı ve Tam Bağlantılı Katmandan (TBK) oluşmaktadır. Şekil 3.8'de temel bir KSA mimarisi verilmiştir. Burada K ile ifade edilen katmanlar konvolüsyon katmanını, R ile ifade edilen katmanlar rektifiye doğrusal birim (ReLU) aktivasyon fonksiyonunu, H ile ifade edilen katman havuzlama katmanını ve TBK ile ifade edilen kısım da tam bağlantılı katmanı temsil etmektedir. Bu katmanların detaylı analizi takip eden alt bölümlerde verilmiştir.



Şekil 3.8. Temel KSA yapısı

3.3.1.1. Konvolüsyon katmanı

Konvolüsyon katmanı, KSA'ya adını da veren en önemli katmandır. Ağa verilen giriş görüntüsü ilk olarak bu katmana gelir. Bu katmanda görüntüye farklı komşuluk oranları belirlenen matrisler (filtreler) uygulanarak görüntüdeki farklı özellikleri temsil eden özellik haritaları çıkarılır. Uygulanan filtrelerdeki parametreler sabit değildir, eğitilebilir. Her bir döngü sonrasında geri yayılım algoritmasıyla her bir satır ve sütundaki değerler güncellenir. Şekil 3.9'da konvolüsyon işleminin nasıl yapıldığını gösteren bir örnek verilmiştir.



Şekil 3.9. Konvolüsyon işlemi

Filtrenin altında belirtilen parametrelerde f filtre boyutunu, s kaydırma adımını (stride), p de doldurma (padding) parametrelerini temsil etmektedirler. Kaydırma adımı görüntü üzerinde gezdirilen filtrenin hangi aralıklarla gezdirileceğinin belirtir. Örneğin; burada kaydırma adımı bir seçildiği için birer kare kaydırarak işlem gerçekleştirilir, farklı sayıda kaydırma adımı belirlenseydi o kadar kare kaydırma yapılarak işlemler gerçekleştirilecekti. Şekilde görüldüğü üzere konvolüsyon işleminin ardından elde edilen özellik haritasının boyutu giriş görüntüsünün boyutundan küçüktür. Eğer her iki matrisin de aynı boyutta olması istenirse doldurma işlemi gerçekleştirilir. Bu işlemde giriş

görüntüsü matrisinin çevresine filtre boyutu ve kaydırma adımına uygun olacak biçimde pikseller eklenir. Eklenen bu pikseller belirlenirken sıfır dolgu (zero padding), simetrik dolgu (symmetric padding) gibi farklı dolgu yöntemlerinden yararlanılır. Şekil 3.9'da görüldüğü gibi 6×6 boyutunda bir giriş görüntüsüne 3×3 boyutunda bir filtre ile konvolüsyon işlemi gerçekleştirilmiş ve neticesinde 4×4 boyutunda bir özellik haritası elde edilmiştir. Elde edilen özellik haritasının boyutu Denklem 3.4' deki gibi hesaplanmaktadır.

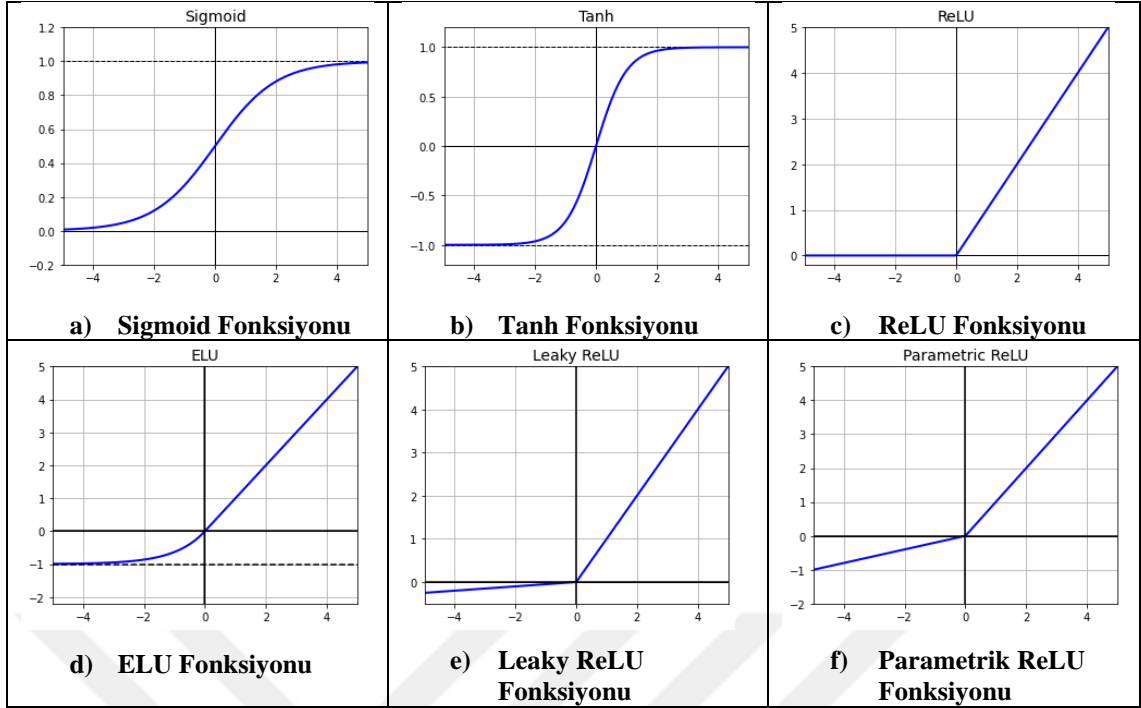
$$\text{Özellik Haritası Boyutu} = \left(\frac{n-f+2p}{s} \right) + 1 \quad (3.4)$$

Denklem 3.4'de n ile giriş görüntüsü boyutu, f ile filtre boyutu, p ile dolgu değeri ve s ile kaydırma adımı sayısı belirtilmektedir.

3.3.1.2. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, konvolüsyon işlemi sonrası elde edilen veriyi doğrusal olmayan hale getirmek için kullanılır. Eğer aktivasyon fonksiyonu uygulanmazsa ağ doğrusal regresyon gibi davranacaktır. Ancak gerçek dünyada kullandığımız bilgiler karmaşık olduğu için verinin doğrusal olmayan biçimde dağılmasına gereksinim duyulur.


Şekil 3.10' da aktivasyon fonksiyonlarına ait grafikler gösterilmiştir. "Sigmoid" ve "tanh" fonksiyonları klasik YSA' da kullanılan fonksiyonlardır. Derin öğrenmede, en sık kullanılan aktivasyon fonksiyonu ReLU'dur. Giriş verisinde negatif değerler sıfıra çekilir, pozitif değerler ise doğrusal bir şekilde dağılır. Bu sayede ağ daha hızlı öğrenir. İlerleyen derin öğrenme çalışmalarında ReLU' nun türevleri olan sızıntı ReLU (Leaky ReLU), üssel ReLU (ELU) ve parametrik ReLU (PReLU) da sıkça kullanılmaktadır. Bu fonksiyonların temel mantığı ReLU' daki ağı hızlandırmak için yapılan negatif değerlerin sıfıra çekilmesi yerine bunların daha küçük katsayılarla çarpılıp negatif değerlere karşılık gelen küçük de olsa bir değer elde etmektir. Yine bu sayede yapılan çalışmalarda ağ eğitiminde doğruluk oranında artış gözlemlenmiştir. Ancak bu fonksiyonların dezavantajı negatif değerleri de işin içine kattığından dolayı eğitim ve test aşamaları ReLU' ya nazaran daha yavaştır.



Şekil 3.10. Aktivasyon fonksiyonları

3.3.1.3. Havuzlama katmanı


Havuzlama katmanları, bilgisayarlı görü görevlerinde kullanılan KSA'ların önemli bir bileşenidir. Konvolüsyon katmanları tarafından üretilen özellik haritalarının uzamsal boyutsallığını azaltmak için kullanılırlar, bu da sonraki katmanların hesaplama maliyetini düşürmekte ve modelin performansını iyileştirmeye yardımcı olabilmektedir. Havuzlama katmanının temel işlemi, girdi özellik haritasını örtüşmeyen veya örtüşen bölgelere bölmek ve tek bir çıktı değeri üretmek için her bölgeye bir işlev (genellikle maksimum veya ortalama havuzlama) uygulamaktır. Ortaya çıkan çıktı özellik haritası, gerçekleştirilen havuzlama işlemlerinin sayısı nedeniyle azaltılmış bir uzamsal boyuta ve artan bir derinliğe sahiptir. Maksimum havuzlama, çıkış değeri olarak her bölgedeki maksimum değer seçildiği, en sık kullanılan havuzlama işlemidir. Örneğin, 2x2 maksimum havuzlamada, giriş özellik haritasının 2x2'lik bir bölgesi birbiriyle örtüşmeyen dört bölgeye bölünür ve her bölgedeki maksimum değer çıkış değeri olarak alınır. Bunun, özellik haritasının uzamsal boyutluluğunu iki kat azaltma etkisi vardır. Ortalama havuzlama da benzer şekilde çalışır, ancak çıkış değeri olarak maksimum yerine her bölgenin ortalama değerini alır. Şekil 3.11'da maksimum ve ortalama havuzlama işlemlerine ait bir örnek verilmiştir.



Şekil 3.11. Havuzlama işlemi

3.3.1.4. Tam bağlantılı katman

Bir KSA'da, tam bağlantılı katman (TBK) konvolüsyon ve havuzlama katmanları tarafından üretilen özellik haritalarını alan ve bunları giriş görüntüsünü sınıflandırmak için kullanan bir katman türüdür. TBK, özellik haritalarını tek boyutlu bir vektöre dönüştürerek ve ardından bu vektörün her ögesini çıkış katmanının her ögesine bağlayarak çalışır. Bu, TBK'nın, konvolüsyon ve havuzlama katmanları tarafından öğrenilen alt düzey özellikleri birleştirerek karmaşık, üst düzey özellikleri tanımayı öğrendiği anlamına gelir. TBK çıktısı, modelin sınıflandırmaya çalıştığı farklı sınıflar üzerinden bir olasılık dağılımıdır. KSA'nın nihai çıktısı, en yüksek olasılığa sahip sınıftır. Şekil 3.12'de bir TBK katmanı örneği verilmiştir.



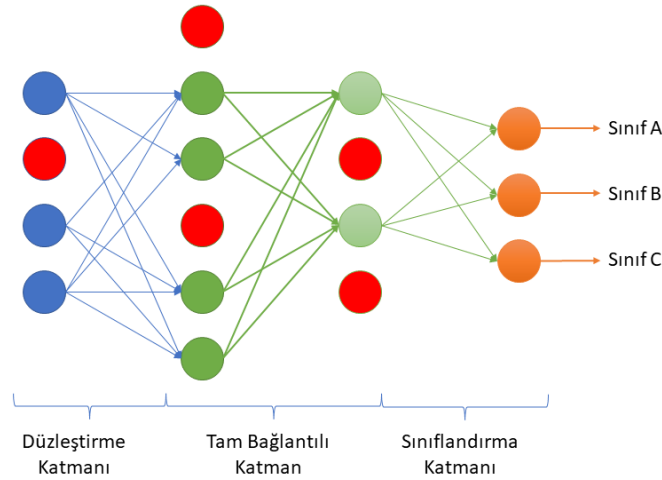
Şekil 3.12. Tam bağlantılı katman

TBK'daki nöronların sayısı tipik olarak konvolüsyon ve havuzlama katmanlarındaki nöronların sayısından çok daha fazladır. Bunun nedeni, tam bağlantılı katmanın girdi görüntüsünü doğru bir şekilde sınıflandırmak için daha karmaşık bir karar

sınıırı öğrenmesi gerekmesidir. TBK'nın dezavantajlarından biri, özellikle özellik haritaları büyük olduğunda hesaplama açısından uzun sürmesidir. Bu sorunu azaltmak için, KSA'lar genellikle aşırı uydurmayı (overfitting) azaltmak ve eğitim hızını artırmak için seyreltme (dropout) ve yığın normalleştirme (batch normalization) gibi teknikleri kullanır. Ek olarak, bazı KSA mimarileri, modeldeki parametre sayısını daha da azaltabilen, TBK yerine genel ortalama havuzlamayı kullanmaktadır.

3.3.1.5. Seyreltme (Dropout) katmanı

Seyreltme katmanı, aşırı uydurmayı önlemek için KSA'lar dahil olmak üzere derin sinir ağlarında kullanılan bir düzenleme tekniğidir. Aşırı uydurma, modelin çok karmaşık olduğu ve eğitim verilerini çok iyi ezberlemeyi öğrendiği derin öğrenme modellerinde yaygın bir sorundur; bu da yeni, görünmeyen verilerde düşük performansa neden olabilir. Seyreltme tekniği, her eğitim yinelemesi sırasında ağdaki belirli bir nöron oranını rastgele bırakarak (nöron çıkışı sıfıra ayarlayarak) çalışır. Bu, modelin herhangi bir belirli nörona bağımlılığını azaltma etkisine sahiptir, modeli daha sağlam hale getirir ve aşırı uyum sağlama olasılığını azaltır. Seyreltme katmanı tipik olarak konvolüsyon katmanı veya TBK'dan sonra yerleştirilir. Eğitim sırasında, katmandaki her bir nöronun, ayarlanabilen bir hiper parametre olan, seyreltme olasılığı vardır. Çıkarım sırasında (yani, yeni veriler üzerinde tahminlerde bulunurken), tüm nöronlar kullanılır ve ağırlıkları, seyreltme olasılığına göre ölçeklenir. Şekil 3.13'te bir seyreltme işlemi örneği verilmiştir. Şekilde kırmızı ile belirtilen nöronlar seyreltme işlemi sonrasında devre dışı bırakılmıştır.



Şekil 3.13. Seyreltme işlemi

Uygulamada, seyreltmenin çok etkili bir düzenleme tekniği olduğu gösterilmiştir ve derin öğrenme modellerinde yaygın olarak kullanılır. Bununla birlikte, modelin iyi bir çözüme yakınsaması için daha fazla döngü için eğitilmesi gerektiğinden eğitim süresini de artırabilir. Ek olarak, modelin çok basit olduğu ve verilerdeki temel kalıpları öğrenmediği durumlarda, çok fazla seyreltme aynı zamanda yetersiz uyum (under fitting) ile sonuçlanabilir. Bu nedenle, seyreltme olasılığının her model ve veri seti için dikkatlice ayarlanması gerekir.

3.3.1.6. Yığın normalleştirme (Batch normalization)

Yığın normalleştirme, modelin doğruluğunun yanı sıra eğitimin hızını ve kararlılığını iyileştirmek için KSA'larda kullanılan bir tekniktir. Yığın normalleştirmenin temel fikri, girdilerin ortalaması ve varyansının bir mini kümedeki tüm eğitim örneklerinde yaklaşık olarak aynı olması için, ağıın her katmanındaki girdileri normalleştirmektir. Bu, eğitim sırasında girdilerin her bir katmana dağılımının değiştiği ve ağıın öğrenmesini zorlaştırdığı bir olgu olan dahili ortak değişken kaymasını azaltmaya yardımcı olur. Ağı, girdileri normalleştirerek verilerdeki temel kalıpları daha kolay öğrenebilir.

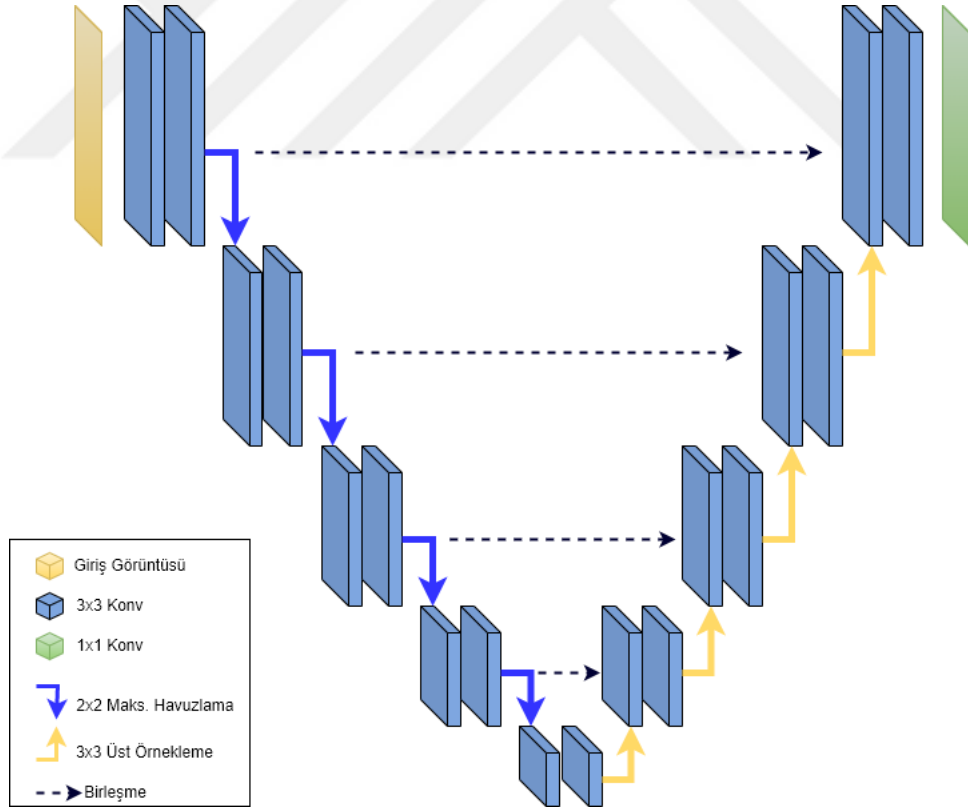
Yığın normalleştirme tipik olarak bir konvolüsyon katmanı veya TBK'dan sonra uygulanır. Eğitim sırasında girdilerin ortalaması ve varyansı mini yığın istatistikleri kullanılarak tahmin edilir ve girdiler bu istatistikler kullanılarak normalleştirilir. Normalleştirilmiş girdiler daha sonra, eğitim sırasında geri yayılım kullanılarak güncellenen öğrenilebilir ölçek ve kaydırma parametreleri kullanılarak dönüştürülür. Çıkarım sırasında (yani, yeni veriler üzerinde tahminler yapmak), eğitim verileri üzerindeki istatistiklerin hareketli ortalaması kullanılarak girdilerin ortalaması ve varyansı tahmin edilir ve girdileri dönüştürmek için ölçek ve kaydırma parametreleri kullanılır.

3.3.2. U-Net

U-Net, ilk defa 2015 yılında biyomedikal görüntü segmentasyonu için kullanılan bir derin öğrenme ağıdır. Ronneberger ve arkadaşları yaptıkları çalışmayla (Ronneberger ve ark., 2015) iletilen ışık mikroskobu görüntüleri (faz kontrastı ve DIC) ile eğitilen U-Net ağını kullanarak, ISBI 2015 (International Symposium on Biomedical Imaging) hücre

izleme yarışmasını büyük bir farkla kazandılar. U-Net'in bu başarısı biyomedikal görüntü segmentasyonu alanında gerçekleştirilen daha sonraki çalışmalara öncülük etmiştir ve 3D U-Net (Çiçek ve ark., 2016), U-Net++ (Zhou ve ark., 2018) ve Attention U-Net (Oktay ve ark., 2018) gibi farklı modeller geliştirilmesinin önünü açmıştır.

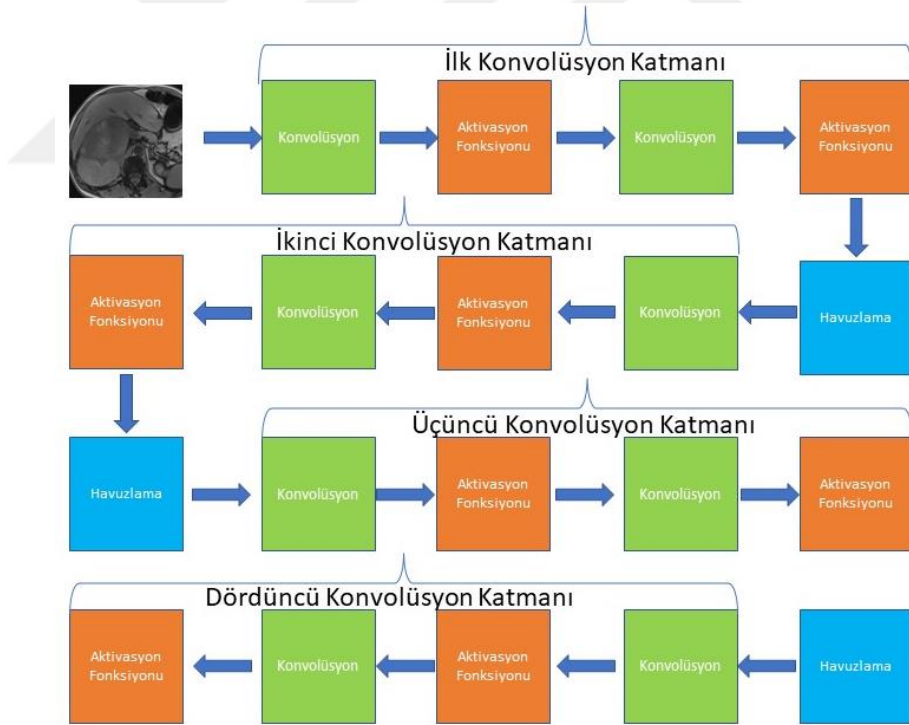
U-Net temel olarak kodlayıcı ve kod çözücü olmak üzere iki kısımdan oluşmaktadır. Şekil 3.14'te tez çalışması kapsamında kullanılan U-Net modelinin genel mimarisi paylaşılmıştır. Burada baştaki sarı blok giriş görüntüsünü, mavi bloklar 3x3 konvolüsyon işlemi ve aktivasyon fonksiyonunu, mavi oklar 2x2 maksimum havuzlama işlemi, sarı oklar 3x3 üst örnekleme (upsampling) işlemi, kesikli siyah çizgiler kodlayıcı ve kod çözücü kısım arasındaki veri birleştirme işlemi, son kısımdaki yeşil blok ise 1x1 konvolüsyon işlemi temsil etmektedirler. Orijinal U-Net modelinde tüm konvolüsyon işlemleri sonrasında aktivasyon fonksiyonu olarak ReLU aktivasyon fonksiyonu, eğitim aşamasında kayıp fonksiyonu olarak İkili Çapraz Entropi (İÇE, Binary Cross Entropy) kullanılmaktadır.



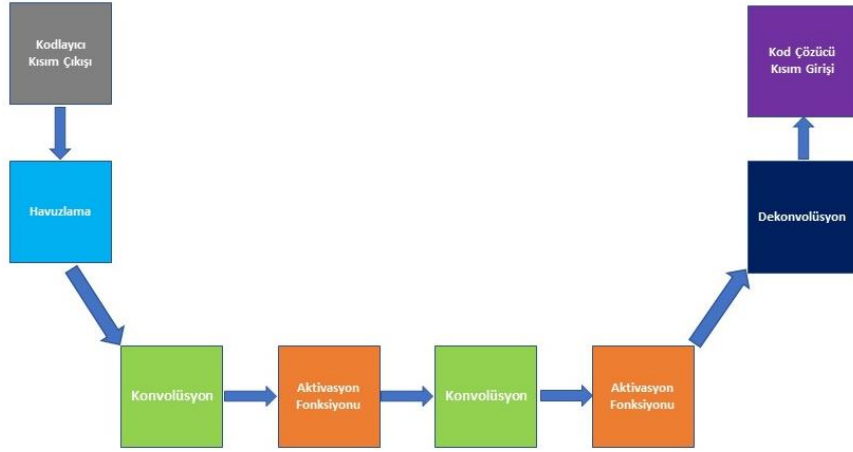
Şekil 3.14. Genel U-Net mimarisi

3.3.2.1. Kodlayıcı kısım

U-Net'in kodlayıcı kısmında ağ girişindeki giriş görüntüsü belirlenen filtre boyutundaki konvolüsyon işleminden ve akabinde aktivasyon fonksiyonundan geçirilir. Bu işlem ağ mimarisini oluşturan kullanıcının belirlediği sayıda tekrar edilir. Sonrasında havuzlama katmanı ile görüntü boyutunda azaltmaya gidilir. Böylece daha az veriyle daha fazla özellik öğrenilmeye çalışılır. Bu işlem yine kullanıcı tarafından belirlenen sayıca tekrarlanır. Şekil 3.15'te kodlayıcı kısma ait yapılan konvolüsyon, aktivasyon fonksiyonları ve havuzlama işlemlerini gösterir örnek ağ yapısı verilmiştir. Burada son aktivasyon fonksiyonundan geçirilen özellik haritaları kodlayıcı kısım ile kod çözücü kısım arasında yer alan dar boğaz (bottle neck) kısmına aktarılır. Şekil 3.16'da darboğaz kısmında gerçekleştirilen işlemleri gösteren görsel paylaşılmıştır. Yapılan üst örnekleme (dekonvolüsyon) işlemi kod çözücü kısımda anlatılacaktır. Darboğaz kısmından sonra kod çözücü kısım işlemlerine geçilir.



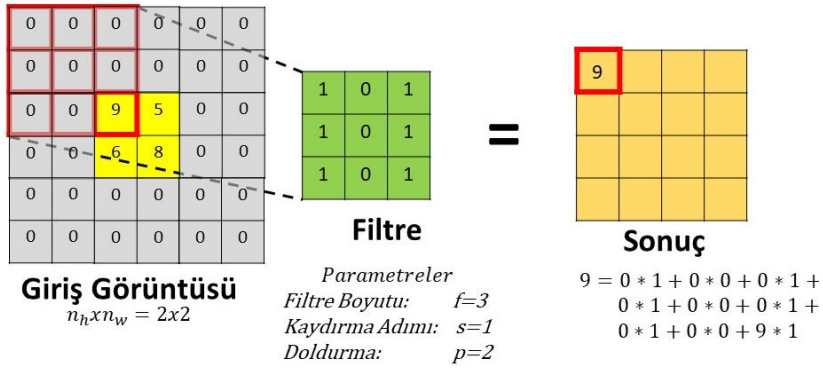
Şekil 3.15. U-Net kodlayıcı kısım



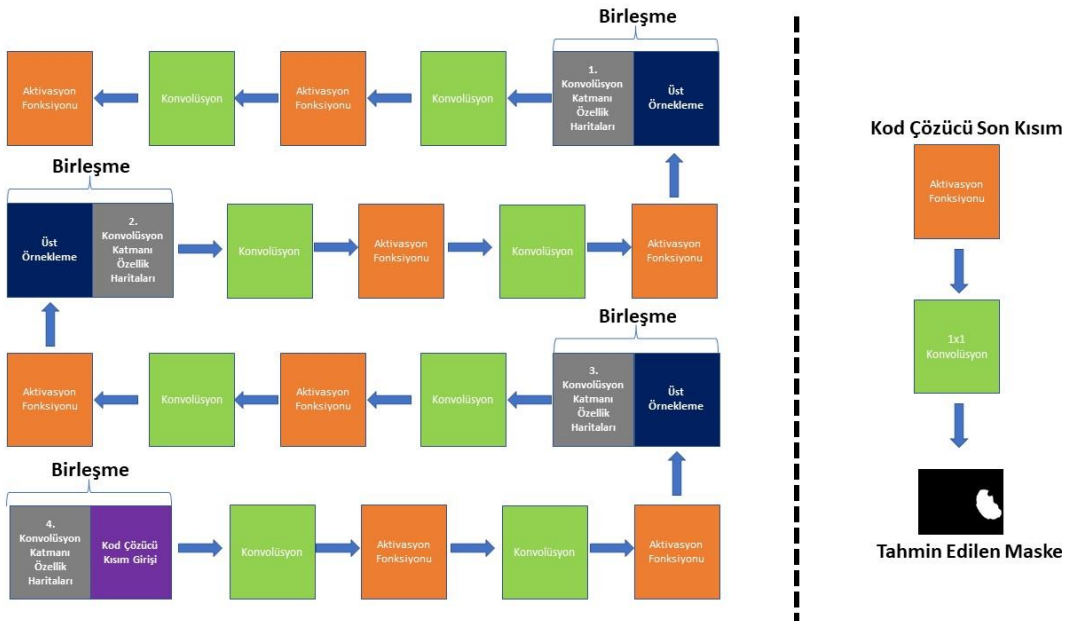
Şekil 3.16. U-Net dar boğaz kısmı

3.3.2.2. Kod çözücü kısım

Bu kısımda dar boğaz kısmına kadar çıkartılan özellik haritaları bu kez tersine işlemle segmente edilmiş görüntü elde edilmeye çalışılır. İlk olarak üst örnekleme işlemiyle özellik haritalarının boyutu büyütülür sonrasında yine kodlayıcı kısımda olduğu gibi sıralı konvolüsyon işlemleri gerçekleştirilir. Şekil 3.17’de üst örnekleme işleminin nasıl gerçekleştirildiğine dair bir örnek verilmiştir. Burada uygulanan filtre ile giriş görüntüsünden daha büyük boyutta bir görüntü elde edilmeye çalışıldığı için işlemler sırasında filtrenin giriş görüntüsündeki bir elemanı içermeyen kısımlarında görüntüye doldurma işlemi uygulanır. Bu örnekte sıfır doldurma (zero padding) işlemi uygulanmıştır. Kodlayıcı kısımdan farklı olarak kod çözücü kısımda her bir üst örnekleme işleminden sonra kodlayıcı kısımda elde edilen özellik haritalarıyla birleştirme işlemi gerçekleştirilir. Bunun amacı kod çözücü kısımda, kodlayıcı kısımda öğrenilen özelliklerin de kullanımıyla daha başarılı bir ağ performansı sağlamaktır. Üst örnekleme ve konvolüsyon işlemleri kodlayıcı kısımda yapılan tekrar sayısı kadar devam ettirilir ve en sonunda özellik haritaları 1x1 bir konvolüsyon filtresinden geçirilerek nihai görüntü elde edilir. Şekil 3.18’de kod çözücü kısmın içerisinde gerçekleşen işlemlere ait görsel paylaşılmıştır.



Şekil 3.17. Üst örnekleme işlemi

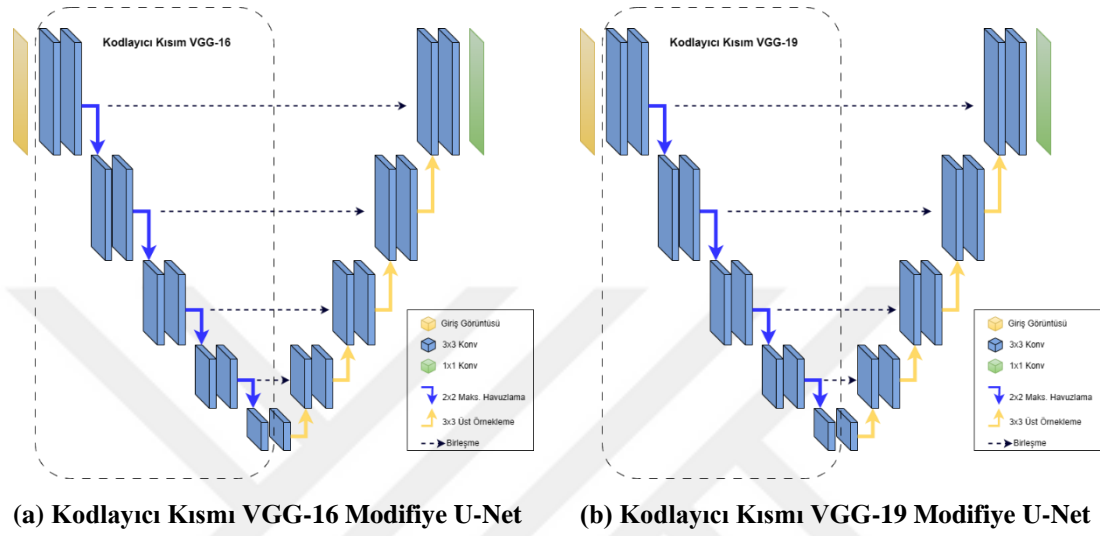


Şekil 3.18. U-Net kod çözücü kısım

3.3.3. Modifiye edilmiş U-Net

Tez çalışması kapsamında segmentasyon çalışmaları için orijinal U-Net modeli üzerinde bazı değişiklikler yapılarak bu modele alternatif olarak modifiye edilmiş U-Net modeli önerilmiştir. Önerilen bu model orijinal modelden iki yönüyle ayrılmaktadır. Bunlardan birincisi konvolüsyon işlemlerinden sonra kullanılan aktivasyon fonksiyonudur. Orijinal modelde kullanılan ReLU aktivasyon fonksiyonu yerine bu modelde ReLU'nun geliştirilmiş bir versiyonu olan PReLU fonksiyonu tercih edilmiştir. İkinci farklılık ise eğitim aşamasında kullanılan kayıp fonksiyonunda gerçekleştirilmiştir. Orijinal modelde kullanılan klasik İÇE kayıp fonksiyonu yerine bu modelde Dice Kayıp fonksiyonu kullanılmıştır.

Ayrıca önerilen modele ek olarak kodlayıcı kısmı transfer öğrenmesiyle farklı ağ modelleriyle (VGG-16, VGG-19) değiştirilmiş iki ayrı ağ yapısı daha oluşturulmuştur. Şekil 3.19’da önerilen modelde yapılan değişikliğin olduğu kısımları gösteren mimariler sunulmuştur. VGG-16 ve VGG-19’un iç yapılarına ait diyagram da Şekil 3.20’de verilmiştir.



Şekil 3.19. Kodlayıcı kısmı farklı modellerle değiştirilmiş modifiye edilmiş U-Net modelleri (a) Kodlayıcı Kısım VGG-16 Modifiye U-Net, b) Kodlayıcı Kısım VGG-19 Modifiye U-Net)

Giriş	Giriş
3x3 Konv., 64	3x3 Konv., 64
3x3 Konv., 64	3x3 Konv., 64
Havuzlama	Havuzlama
3x3 Konv., 128	3x3 Konv., 128
3x3 Konv., 128	3x3 Konv., 128
Havuzlama	Havuzlama
3x3 Konv., 256	3x3 Konv., 256
3x3 Konv., 256	3x3 Konv., 256
3x3 Konv., 256	3x3 Konv., 256
Havuzlama	3x3 Konv., 256
3x3 Konv., 512	Havuzlama
3x3 Konv., 512	3x3 Konv., 512
3x3 Konv., 512	3x3 Konv., 512
Havuzlama	3x3 Konv., 512
3x3 Konv., 512	3x3 Konv., 512
3x3 Konv., 512	Havuzlama
3x3 Konv., 512	3x3 Konv., 512
Havuzlama	3x3 Konv., 512
	3x3 Konv., 512
	3x3 Konv., 512
	Havuzlama

VGG-16

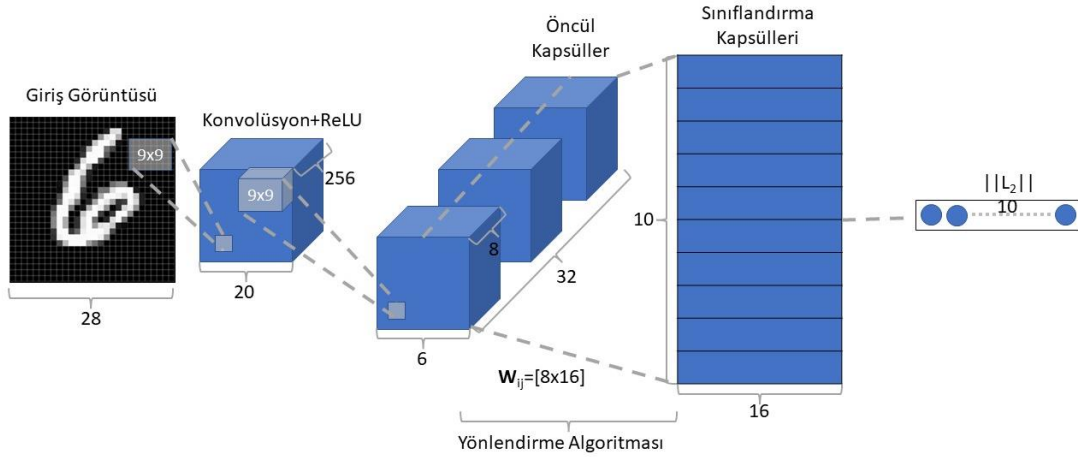
VGG-19

Şekil 3.20. VGG-16 ve VGG-19 katmanları

3.3.4. Kapsül ađlar

KSA özellikle nesne tanıma problemlerinde çok başarılı sonuçlar vermiştir; ancak bir görüntüde meydana gelen deđişimleri iyi algılayamamaktadır. Örneđin; bir yüz görüntüsünde göz ile ağız yer deđiştğinde bunu KSA yine bir yüz olarak tanımaktadır. Ancak; göz ile ağız yer deđiştği için bu görüntü artık bir yüz olmaktan çıkmaktadır. İşte bu mantıktan yola çıkan Geoffrey Hinton ve öğrencileri kapsül ađları tanıtmışlardır (Sabour ve ark., 2017). Kapsül ađlarda, KSA'dan farklı olarak görüntü üzerindeki nesnelerin vektörel olarak birbirleriyle olan ilişkisi göz önüne alınmaktadır. Örneđin; ağız ile gözün birbirlerine göre olan konumları vektörel olarak verilmekte bu vektörel ilişki bozulduğunda ise görüntünün de orijinal görüntü olmadığı gözlemlenmektedir.

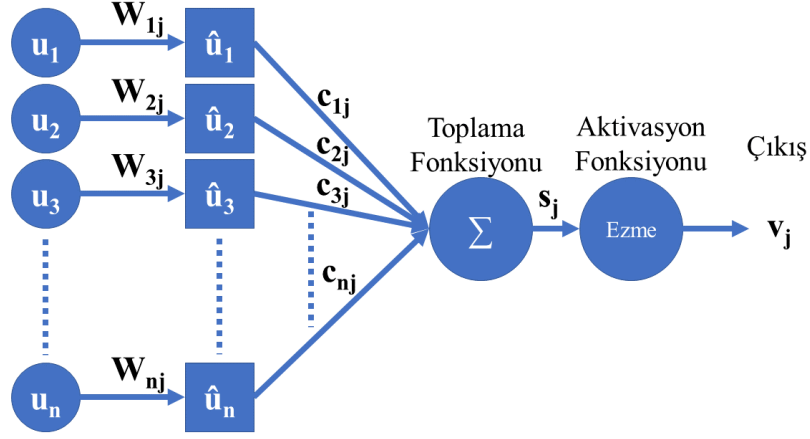
Kapsül ađlar kodlayıcı ve kod çözücü olmak üzere iki kısımdan oluşmaktadır. Bir kapsül ađındaki kodlayıcı giriş görüntüsünü, görüntünün içeriđi hakkında tahminlerde bulunmak için kullanılabilir bir dizi üst düzey özelliđe dönüştürmekten sorumludur. Kodlayıcı kısım konvolüsyon katmanı, öncül kapsül ve sınıflandırma kapsülü olmak üzere üç bölümden oluşmaktadır. Konvolüsyon katmanı, giriş görüntüsünden yerel özellikleri çıkarmak için kullanılır. Bu katmanlar, giriş görüntüsüne filtreler uygulayarak görüntünün farklı yönlerini vurgulayan özellik haritalarını üretir. Her konvolüsyon katmanının çıkışı, daha sonra tipik olarak, ađa doğrusal olmamayı sağlamak için bir aktivasyon fonksiyonundan geçirilir. Konvolüsyon katmanlarından sonra, çıktı öncül kapsül katmanına geçirilir. Öncül kapsül, görüntüdeki belirli bir nesneyi veya bir nesnenin bir parçasını temsil eden bir nöron grubudur. Her kapsül, temsil ettiđi nesnenin varlığını, pozunu ve olasılıđını temsil eden vektörlerden oluşur. Varlık vektörü, nesnenin görüntüde bulunup bulunmadığını, poz vektörü nesnenin yönünü ve ölçeđini, olasılık vektörü ise nesnenin var olma olasılıđını gösterir. Öncül kapsül katmanındaki çıktılar ile daha yüksek seviye kapsüller olan sınıflandırma kapsüllerinin nasıl birleştirebileceđini belirlemek için dinamik bir yönlendirme algoritması kullanılır. Dinamik yönlendirmenin amacı, aynı nesneyi temsil eden kapsüllerin çıktılarının birleştirilmesini, farklı nesnelere temsil eden kapsüllerin çıktılarının ise ayrı tutulmasını sağlamaktır. Böylece giriş görüntüsünün sınıfı tahmin edilir. Şekil 3.21'de kapsül ađının kodlayıcı kısmını gösteren temsili bir örnek verilmiştir (Sabour ve ark., 2017).



Şekil 3.21. Kapsül ağ kodlayıcı mimarisi

Şekil 3.21’de MNIST veri setinden oluşan 28×28 boyutundaki giriş görüntülerine 9×9 boyutunda 256 adet filtre, kaydırma adımı 1 seçilerek uygulanmış ve $20 \times 20 \times 256$ boyutunda özellik haritaları elde edilmiştir. Sonrasında elde edilen özellik haritaları ReLU aktivasyon fonksiyonundan geçirilerek aktive edilmiştir. Sonraki aşamada aktive edilen bu özellik haritalarına 256 tane 9×9 boyutundaki filtreler, kaydırma adımı 2 seçilerek uygulanmıştır. Bu işlemler sonucunda $6 \times 6 \times 256$ boyutunda özellik haritaları elde edilmiştir. Öncül kapsül bölümünde ise elde edilen bu özellik haritaları yeniden şekillendirilir ve kapsüllere dönüştürülür. Bu bölümde, 256 özellik haritası her birinin derinliği 8 olacak şekilde kapsüllere ayrılır ve toplamda 32 adet öncül kapsül elde edilir. Her bir kapsül $6 \times 6 \times 8$ boyutundadır.

Öncül kapsülde bulunan kapsüller görüntünün ait olduğu sınıfı belirlemek için daha yüksek seviye kapsül katmanı olan sınıflandırma kapsülüne yönlendirilirler. Şekil 3.22’de öncül kapsülden sınıflandırma kapsüle geçişin nasıl olduğuna dair görsel verilmiştir. Burada u_n öncül kapsül vektörlerini, W_{ij} dönüşüm (poz) matrisini, \hat{u}_{ji} tahmin vektörlerini, c_{ij} eşleşme katsayılarını, s_j matris çarpımlarının toplamını (yüksek seviye kapsül katmanının toplam girişi), v_j ise bu toplamın aktivasyon fonksiyonundan geçirilmesi sonucu elde edilen yüksek seviye kapsül katmanının çıkış vektörünü yani görüntünün ait olduğu sınıfa dair ağın nihai tahmin vektörünü temsil etmektedir.



Şekil 3.22. Öncül kapsülden sınıflandırma kapsülüne geçiş

Afin dönüşümü, bir görüntünün veya özellik haritasının ötelenmesini, döndürülmesini, ölçeklenmesini ve kırılmasını içeren doğrusal bir dönüşümdür. Bir kapsül ağında, giriş görüntüsündeki bir nesnenin pozunu hesaplamak için afin dönüşümler kullanılır. Matematiksel olarak Denklem 3.5’te görüldüğü gibi öncül kapsül vektörlerinin dönüşüm matrisiyle çarpımıyla uygulanır ve böylece ilgili görüntünün ait olduğu sınıfa dair tahmin vektörleri elde edilir. Sonrasında bu tahmin vektörleri dinamik yönlendirme algoritmasıyla hesaplanan c_{ij} eşleşme katsayılarıyla çarpılır ve bu çarpımların toplamı s_j toplam girişi verir (Denklem 3.6).

$$\hat{u}_{j|i} = W_{ij}u_i \quad (3.5)$$

$$s_j = \sum_i c_{ij}\hat{u}_{j|i} \quad (3.6)$$

Kapsül ağlar, KSA’nın aksine görüntü üzerinde vektörel ilişkiler üzerinden işlemlerini gerçekleştirdiğinden dolayı derin öğrenmede kullanılan aktivasyon fonksiyonları yerine kendine özgü bir vektörel aktivasyon fonksiyonu kullanmaktadırlar. Bu aktivasyon fonksiyonu da “Ezme (*Squash*)” fonksiyonu olarak adlandırılmaktadır. Denklem 3.7’de ezme fonksiyonunun denklemleri verilmiştir. Burada, s_j toplam girişi, $\|s_j\|$ toplam girişin normunu, v_j ise aktivasyon fonksiyonunun çıkış vektörünü ifade etmektedir. Ezme fonksiyonu vektörlerin uzunluğuna göre 0 ila 1 arasında değerler almasını sağlamaktadır. Eğer vektörlerin uzunluğu büyükse 1’e, küçükse 0’a yakınsar. Böylece bir kapsülün çıkış vektörünün uzunluğunun kapsül tarafından temsil edilen mevcut girdide bulunma olasılığı hesaplanmaktadır.

$$v_j = \frac{\|s_j\|^2}{1 + \|s_j\|^2} \frac{s_j}{\|s_j\|} \quad (3.7)$$

3.3.4.1. Dinamik yönlendirme algoritması

Kapsül ağlarında dinamik yönlendirme algoritmaları, ağın nesnelere şekillerine ve uzamsal ilişkilerine göre tanınması ve sınıflandırmasına yardımcı olur. Algoritma, daha düşük seviye kapsüllerden daha yüksek seviye kapsüllere, daha düşük seviye kapsüllerin belirli bir nesneyi veya özelliği temsil etme olasılığına göre bilgiyi yönlendirir. Bu yönlendirme işlemi dinamiktir, yani ağın öğrenmesi ve uyum sağlama sırasında zamanla değişebilir. Dinamik yönlendirmenin amacı, nesnenin farklı parçaları arasındaki uzamsal ilişkileri dikkate alarak daha doğru tanımlamayı ve sınıflandırmayı sağlamaktır. Bu, özel filtrelerle çalışan ve özellikler arasındaki uzamsal ilişkileri dikkate almayan geleneksel KSA'ya karşıt bir yaklaşımdır.

Çizelge 3.1'de dinamik yönlendirme algoritmasının kod işleyişi verilmiştir. İlk satırda algoritmanın prosedürü mevcuttur. Burada, r algoritmanın ne kadar tekrarlanacağını, l düşük seviye kapsül katmanını ve \hat{u}_{ji} bu katmanın çıkışında elde edilen tahmin vektörlerini belirtmektedir. İkinci satırda b_{ij} , l ve $l+1$ katmanları arasındaki eşleşme olasılığını belirten başlangıç olasılıklarının logaritmasıdır (logit) ve başlangıçta değeri '0' alınmaktadır. Üçüncü satırda algoritmanın ne kadar döndürüleceği belirlenen r sayısına belirtilir. Dördüncü satırda l katmanındaki b_i değerleri *softmax* fonksiyonundan geçirilerek c_i eşleşme katsayıları belirlenir (Denklem 3.8). Eşleşme katsayıları çıkıştaki sınıf sayısına göre toplamları 1 olacak şekilde her bir sınıf için bir eşleşme katsayısını temsil etmektedirler. Beşinci satırda düşük seviye kapsüllerin tahmin vektörleri (\hat{u}_{ji}) ile eşleşme katsayıları (c_{ij}) çarpılıp toplanır ve yüksek seviye kapsülün girişi (s_j) elde edilir (Denklem 3.6). Altıncı satırda elde edilen bu çıkış vektörü (s_j) *Ezme* aktivasyon fonksiyonundan geçirilerek normalize edilir ve böylece yüksek seviyeli kapsülün çıkış vektörü (v_j) elde edilir (Denklem 3.7). Son satırda ise düşük seviye kapsülün çıkış vektörüyle (\hat{u}_{ji}) yüksek seviye kapsülün çıkış vektörü (v_j) nokta çarpımı yapılır. Elde edilen değer pozitifse düşük seviyeli kapsülün çıkış vektörüne benzediği, negatifse benzemediğine karar verilir ve b_{ij} katsayısı buna göre güncellenir (Denklem 3.9). Algoritma belirlenen r değerince tekrarlanır ve üçüncü satırdan işlemlere devam eder.

Çizelge 3.1. Dinamik Yönlendirme Algoritması

```

1: prosedür Yönlendirme ( $\hat{u}_{j|i}, r, l$ )
2:    $l$  katmanındaki tüm kapsüller  $i$  ve  $l+1$  katmanındaki tüm kapsüller  $j$ :  $b_{ij} \leftarrow 0$ 
3:   for  $r$  iterasyon do
4:      $l$  katmanındaki tüm  $i$  kapsülleri için:  $c_i \leftarrow \text{softmax}(b_i)$ 
5:      $l+1$  katmanındaki tüm  $j$  kapsülleri için:  $s_j = \sum_i c_{ij} \hat{u}_{j|i}$ 
6:      $l+1$  katmanındaki tüm  $j$  kapsülleri için:  $v_j = \text{Ezme}(s_j)$ 
7:      $l$  katmanındaki tüm  $i$  kapsülleri ve  $l+1$  katmanındaki tüm  $j$  kapsülleri için:
           
$$b_{ij} \leftarrow b_{ij} + \hat{u}_{j|i} \cdot v_j$$

   return  $v_j$ 

```

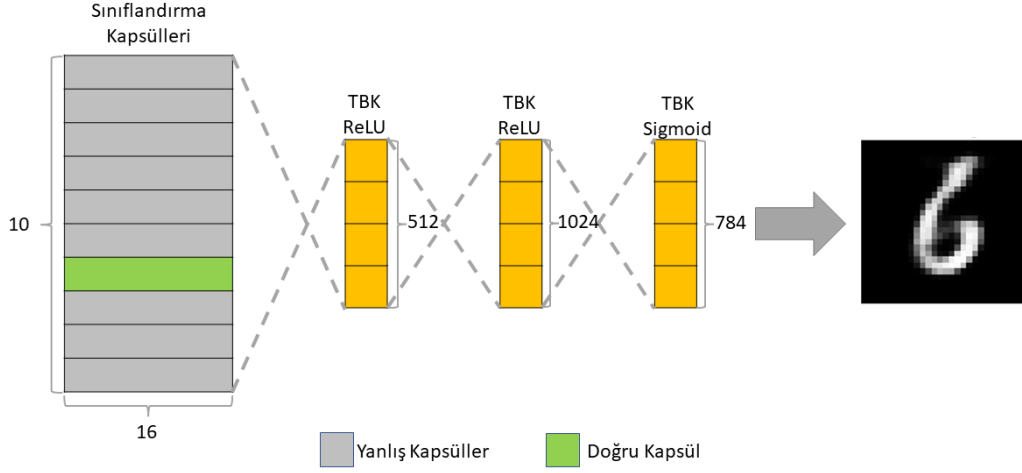
$$c_{ij} = \frac{\exp(b_{ij})}{\sum_k \exp(b_{ik})} \quad (3.8)$$

$$b_{ij} \leftarrow b_{ij} + \hat{u}_{j|i} \cdot v_j \quad (3.9)$$

3.3.4.2. Kod çözücü

Kapsül ağındaki kod çözücünün görevi giriş görüntüsünü yeniden oluşturmaktır. Kod çözücü kısmın sınıflandırmaya doğrudan bir katkısı bulunmamaktadır. Bir kapsül ağda bir kod çözücünün kullanılması, ağı hem sınıflandırma kaybı hem de yeniden yapılandırma kaybı kullanılarak eğitilmesine izin verir, bu da ağı genelleştirme performansını iyileştirmeye yardımcı olabilir. Giriş görüntüsünü kapsül aktivasyonlarından yeniden yapılandırarak ağ, giriş görüntüsündeki nesnelerin hem kimliğini hem de pozunu yakalayan anlamlı özellikleri öğrenmeye teşvik edilir.

Şekil 3.23'te MNIST veri seti için oluşturulan kapsül ağ kod çözücü yapısı verilmiştir. Burada, giriş görüntüsünün kodlayıcı kısımda eğitim sonunda tahmin edilen sınıfa ait kapsül sırasıyla 512 ve 1024 nörondan oluşan TBK'lara bağlanmıştır. Burada aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Son kısımda ise oluşturulmak istenen görüntü boyutuna ($28 \times 28 = 784$) göre belirlenen nöronlara bağlanır. Bu aşamada diğer TBK'lardan farklı olarak çıkışta Softmax aktivasyon fonksiyonundan geçirilir.



Şekil 3.23. Kapsül ağ kod çözücü mimarisi

3.3.4.2. Kayıp fonksiyonu

Kayıp (hata) fonksiyonunun öğrenme sürecinde gerekli geri bildirim sağladığı bilinmektedir. Kapsül ağları, daha verimli bir parametre ayarı için marj kaybının (margin loss) ve yeniden yapılandırma kaybının (reconstruction loss) ağırlıklı toplamını kullanır. Denklem 3.10' de toplam kayıp fonksiyonunun denklemi verilmiştir.

Burada L_{Toplam} , L_{Marj} ve $L_{Yeniden Yapılandırma}$ sırasıyla toplam kaybı, marj kaybını ve yeniden yapılandırma kaybını temsil etmektedirler. Orijinal makalede α değeri 0,0005 olarak alınmıştır (Sabour ve ark., 2017). Yani, yeniden yapılanma kaybının toplam kayıp hesabına küçük bir katkısı vardır. Bu yüzden, toplam kayıp marj kaybına eşit alınabilir.

$$L_{Toplam} = L_{Marj} + \alpha L_{Yeniden Yapılandırma} \quad (3.10)$$

Marj kaybı kısaca her bir sınıf kapsülü için tahmin edilen tahmin vektörleriyle ilgili sınıf arasındaki toplam hata olarak hesaplanmaktadır. Denklem 3.11'de marj kaybının denklemi verilmiştir. Burada kullanılan parametreler orijinal makale (Sabour ve ark., 2017) baz alınarak doğru sınıflar için $T_k = 1$, yanlış sınıflar için $T_k = 0$ alınmaktadır. Ayrıca m^+ , m^- ve λ sırasıyla 0,9, 0,1 ve 0,5 alınmaktadır. Eğer tahmin vektörü doğru etikete sahipse eşitliğin sol tarafı, yanlış etikete sahipse eşitliğin sağ tarafındaki denkleme göre hesaplamalar gerçekleştirilir. Verilen m değerlerine göre doğru sınıfta bir etiket için %90 ve üzerinde sınıflandırma başarısı varsa kayıp değeri 0, %90'ın altındaysa sıfırdan farklı bir kayıp değeri alır. Aynı şekilde yanlış sınıfta bir etiket değeri için %10 ve altında


sınıflandırma başarısı varsa kayıp değeri 0, %10'un üzerindeyse sıfırdan farklı bir kayıp değeri alır.

$$L_k = T_k \max(0, m^+ - \|v_k\|)^2 + \lambda(1 - T_k) \max(0, \|v_k\| - m^-)^2 \quad (3.11)$$

3.3.5. Önerilen kapsül sınıflandırma ağ yapısı

Tez çalışması kapsamında, sınıflandırma çalışmalarında kullanılmak üzere yeni bir kapsül ağ yapısı önerilmiştir. Önerilen kapsül ağ yapısı Şekil 3.24'te verilmiştir. Önerilen bu yapı orijinal kapsül ağ yapısından şu özellikleriyle ayrılmaktadır:

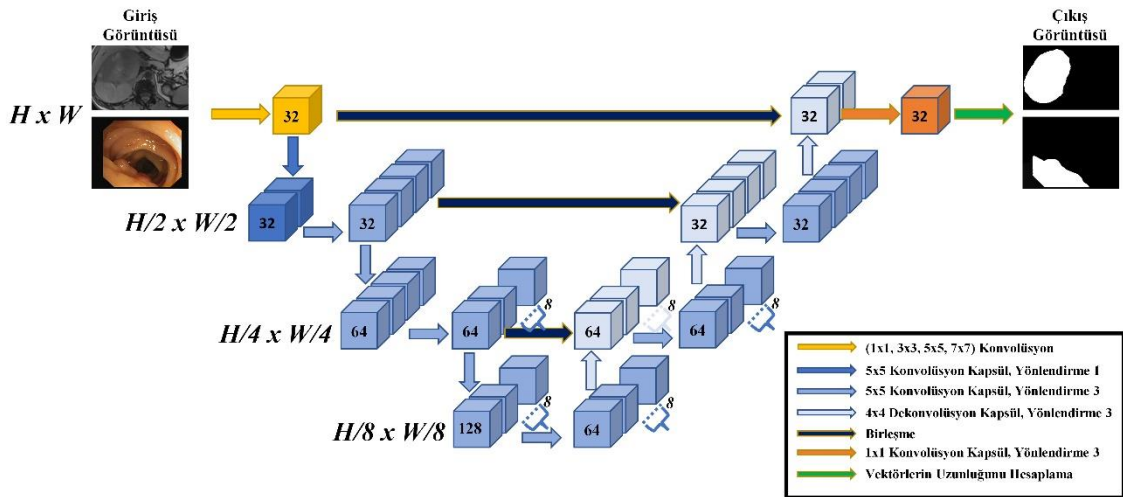
- Giriş görüntüsü boyutu MNIST'te kullanılan 28x28 yerine daha büyük boyuta 128x128'e çevrildi.
- İlk konvolüsyon işleminde kullanılan kaydırma adımı (s) 1 yerine 2 olarak, filtre boyutu (f) ise 9 yerine 5 olarak seçildi.
- İkinci konvolüsyon aşamasında kaydırma adımı yine 2 olarak seçildi; ancak burada orijinal modelden farklı olarak doldurma işlemi uygulandı. Böylece işlem sonucunda boyutlar aynı kaldı.
- Sınıflandırma kapsülü yapılan ikili sınıflandırma çalışmalarına göre yeniden şekillendirildi.
- Kod çözücü kısımda kullanılan TBK da ki nöron sayıları 512, 1024 yerine 64,128 olarak belirlendi. Ayrıca son TBK katmanı da giriş görüntüsü boyutuna uygun olacak şekilde belirlendi.



Şekil 3.24. Sınıflandırma için önerilen kapsül ağ mimarisi

Tez çalışması kapsamında orijinal SegCaps modelinden farklı olarak konvolüsyon ve kapsül katmanlarında kullanılan hiper parametre değerlerine göre yeni bir kapsül segmentasyon ağı önerilmiştir. Şekil 3.26’da önerilen kapsül segmentasyon ağı yapısı verilmiştir. Bu yapının Şekil 3.25’teki modelden farklılıkları şu şekilde sıralanabilir:

- Hem konvolüsyon hem de kapsül katmanlarında kullanılan filtre ve kapsül sayıları artırıldı. Böylece görüntü üzerinde daha ayrıntılı ve üst seviye bilgiler çıkarılabilir.
- Girişteki konvolüsyon katmanında farklı filtre boyutları (1×1 , 3×3 , 5×5 , 7×7) denenerek seçilen filtre boyutunun modelin performansına etkisi gözlemlenmiştir.
- Ayrıca konvolüsyon katmanının çıkışında kullanılan ReLU aktivasyon fonksiyonu yerine PReLU aktivasyon fonksiyonu tercih edilerek çalışma performansının artırılması amaçlanmıştır.



Şekil 3.26. Önerilen kapsül segmentasyon ağı mimarisi

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde tez çalışması kapsamında kullanılan istatistiksel metrikler ve her bir veri seti için çalışma sonuçları ayrı bölümler halinde incelenecektir. Bu minvalde sırasıyla mamogram görüntülerinde iyi/kötü huylu kitle sınıflandırması, abdomen görüntüler üzerinde iyi/kötü huylu adrenal lezyon sınıflandırması ve bu lezyonların segmentasyonu, kolonoskopi görüntüleri üzerinde poliplerin segmentasyonu ve röntgen görüntülerinde zatürre/sağlıklı sınıflandırması çalışmalarına yer verilecektir.

4.1. Tez Çalışmasında Kullanılan İstatistiksel Metrikler

Tez çalışması kapsamında gerçekleştirilen sınıflandırma ve segmentasyon çalışmalarının değerlendirilmesi için literatürde sıklıkla kullanılan performans metriklerine başvurulmuştur. Çalışmalarda kullanılan metrikler şu şekildedir:

- Doğruluk (Accuracy - DOĞ)
- Duyarlılık (Sensitivity - DUY)
- Özgüllük (Specificity - ÖZG)
- Kesinlik (Precision - KES)
- F1-skor (F1-score - F1-skor)
- Eğri Altında Kalan Alan (Area Under Curve (AUC) - EAA)
- Kappa skor (Kappa score - Kappa skor)
- Dice Katsayısı (Dice Coefficient - DK)
- Jaccard Oranı (Jaccard Rate - JO)
- Hausdorff Mesafesi (Hausdorf Distance - HM)

Sınıflandırma çalışmaları için kullanılan doğruluk, duyarlılık, özgüllük, kesinlik, F1-skor, Kappa skor, EAA skorları ve karmaşıklık matrisi metriklerinin matematiksel ifadeleri sırasıyla Denklem 4.1-4.13 arasında verilmiştir. Burada, Denklem 4.6'da verilen Kappa skor hesabında kullanılan parametrelerin açıklanması için Denklem 4.7-4.10 arasında ilgili parametrelerin matematiksel ifadelerine yer verilmiştir. Ayrıca Denklem 4.11 ve 4.12'de ifade edilen DPO ve YPO ifadeleri de EAA kalan hesabı için önemli parametrelerdir. Şekil 4.1'de EAA hesabında kullanılan İşlem Karakteristik Eğrisi (İKE, Receiver Operating Characteristic) eğrisi paylaşılmıştır.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4.1)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4.2)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (4.3)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4.4)$$

$$\text{F1 - skor} = \frac{2(\text{Kesinlik} \cdot \text{Duyarlılık})}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4.5)$$

$$\text{Kappa}(\kappa) = \frac{p_0 - p_e}{1 - p_e} \quad (4.6)$$

$$p_0 = \frac{TP+TN}{(TP+TN+FP+FN)} \quad (4.7)$$

$$p_{\text{empire}} = \frac{TN+FP}{(TP+TN+FP+FN)} \times \frac{TN+FN}{(TP+TN+FP+FN)} \quad (4.8)$$


$$p_{\text{theory}} = \frac{TP+FN}{(TP+TN+FP+FN)} \times \frac{TP+FP}{(TP+TN+FP+FN)} \quad (4.9)$$

$$p_e = p_{\text{empire}} + p_{\text{theory}} \quad (4.10)$$

$$\text{Doğru Pozitif Oranı (DPO)} = \frac{DP}{DP+YN} \quad (4.11)$$

$$\text{Yanlış Pozitif Oranı (YPO)} = \frac{YP}{YP+DN} \quad (4.12)$$

$$\text{Karmaşıklık Matrisi} = \begin{bmatrix} DP & YP \\ YN & DN \end{bmatrix} \quad (4.13)$$




Şekil 4.1. İşlem Karakteristik Eğrisi (İKE)

Segmentasyon çalışmalarında doğru bir analiz için duyarlılık ve özgüllük metriklerinin yanı sıra DK, JO ve HM metrikleri de kullanılmıştır. Denklem 4.14-4.16'da sırasıyla bu metriklerin matematiksel ifadeleri verilmiştir. Ayrıca Şekil 4.2'de HM hesaplanmasına ait bir görsel de sunulmuştur.

$$\text{Dice Katsayısı (DK)} = \frac{2xDP}{(DP+YP)+(DP+YN)} \quad (4.14)$$

$$\text{Jaccard Oranı (JO)} = \frac{DP}{DP+YP+YN} \quad (4.15)$$

$$\begin{aligned}
HM &= \begin{aligned}
&hm(X, Y) = \max_{x \in X} \min_{y \in Y} \|x - y\|_2 \\
&hm(Y, X) = \max_{y \in Y} \min_{x \in X} \|x - y\|_2 \\
&HM(X, Y) = \max (hm(X, Y), hm(Y, X))
\end{aligned}
\end{aligned} \tag{4.16}$$



Şekil 4.2. Hausdorff mesafesi hesaplanması

HM metriği dışındaki tüm metriklerin hesaplanmasında Doğru Pozitif (DP), Yanlış Pozitif (YP), Doğru Negatif (DN) ve Yanlış Negatif (YN) parametreleri kullanılmaktadır. DP değeri, sınıflandırma ve segmentasyon çalışmalarında pozitif olarak etiketlenen değerlerin eğitim sonucunda da pozitif olarak tahmin edilmesini ifade etmektedir. YP değeri, sınıflandırma ve segmentasyon çalışmalarında negatif olarak etiketlenen değerlerin eğitim sonucunda pozitif olarak tahmin edilmesini belirtmektedir. DN değeri sınıflandırma ve segmentasyon çalışmalarında negatif olarak etiketlenen değerlerin eğitim sonucunda da negatif olarak tahmin edilmesidir. YN değeri, sınıflandırma ve segmentasyon çalışmalarında pozitif olarak etiketlenen değerlerin eğitim sonucunda negatif olarak tahmin edildiğini göstermektedir (Ruuska ve ark., 2018). HM hesaplanmasında ise Şekil 4.2’de görüldüğü üzere gerçek ve tahmin edilen iki görüntünün sınırları arasındaki maksimum uzaklık Denklem 4.16’daki gibi hesaplanır (Huttenlocher ve ark., 1993).

4.2. Mamogram Veri Setiyle Yapılan Sınıflandırma Çalışması

Mamogram, meme kanserini tespit ve teşhis etmek için kullanılan bir tıbbi görüntüleme türüdür. Meme dokusunun görüntülerini oluşturan düşük dozlu bir röntgendir ve herhangi bir anormalliği veya kanser belirtisini tanımlamak için tıp uzmanları tarafından analiz edilebilir.

Mamogramlardan iyi huylu/ kötü huylu kitle sınıflandırılması önemlidir çünkü meme kanserinin erken tespit ve teşhisine yardımcı olabilir. Meme kanseri ne kadar erken tespit edilirse, başarılı tedavi ve iyileşme şansı da o kadar yüksek olur.

Derin öğrenme algoritmaları, mamogram görüntülerinin sınıflandırma sürecini potansiyel olarak otomatikleştirebilir, bu da tıp uzmanları için zaman ve kaynak tasarrufu

sağlayabilir, teşhislerin doğruluğunu ve tutarlılığını artırabilir. Ayrıca, derin öğrenme modelleri büyük mamogram veri kümelerinden öğrenerek anormallikleri belirleme ve sınıflandırma becerilerini geliştirebilir, bu da potansiyel olarak daha erken teşhis ve hastalar için daha iyi sonuçlar elde edilmesini sağlayabilir.

Bu bölümde, mamogram veri setiyle gerçekleştirilen sınıflandırma çalışmaları incelenecektir. Bu bağlamda ilk olarak KSA ve transfer öğrenmesi kullanılarak sonrasında da kapsül ağırlar kullanılarak yapılan sınıflandırma çalışmalarına yer verilmiştir.

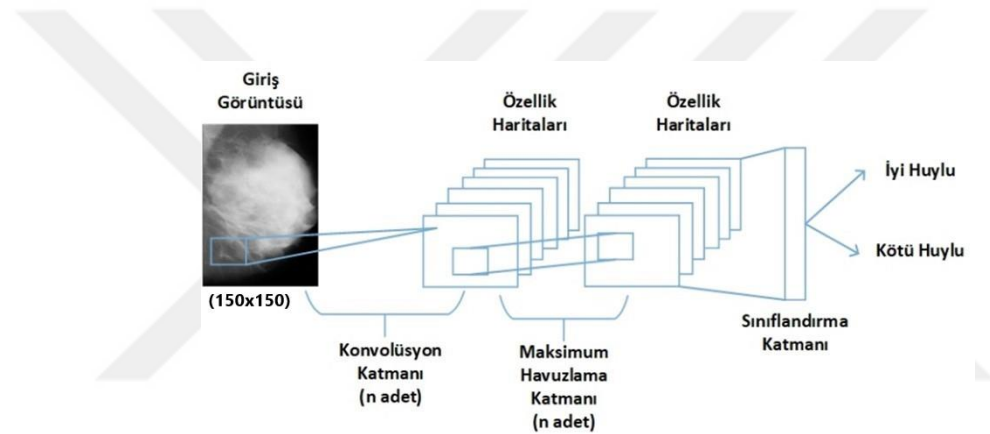
Çalışmada 64 iyi huylu, 52 kötü huylu kitleden oluşan MIAS mamogram veri seti kullanılmıştır (Suckling, 1994; Hepsağ ve ark., 2017; Li ve ark., 2018). Veri setindeki görüntülere eğitim öncesinde iki farklı ön işlem uygulanmış ve böylece iki ayrı veri seti oluşturulmuştur. Veri setlerinin anlatıldığı bölümde Şekil 3.1’de uygulanan ön işlemlere ait örnekler verilmiştir. Ön işlemler sonrasında elde edilen veri setlerine her bir görüntü için -20 dereceden +20 dereceye kadar her 4 derecede bir görüntü kaydırma işlemi uygulanarak her görüntünün toplamda 10 farklı yeni görüntüsü elde edilmiştir. Böylece; her bir görüntü için 11 adet (1 orijinal + 10 yeni görüntü) kayıt elde edilmiştir. Gerçekleştirilen bu işlemten sonra veri setleri 704 iyi huylu ve 572 kötü huylu kitle içeren görüntüden oluşur hale gelmektedir. Veri artırımı sonrası elde edilen görüntülere ait örnekler Şekil 4.3’te verilmiştir.



Şekil 4.3. Döndürülerek veri artırımı yapılmış MIAS görüntüleri (a) -16 derece döndürülerek elde edilen görüntü (b) +16 derece döndürülerek elde edilen görüntü

4.2.1. KSA ve transfer öğrenmesi kullanılarak gerçekleştirilen sınıflandırma çalışması

Bu kısımda, mamogram veri seti üzerinde iyi huylu ve kötü huylu kitle sınıflandırması yapmak için probleme özgü oluşturulan bir klasik KSA yapısı ve farklı transfer öğrenmesi modelleriyle çalışmalar gerçekleştirilmiştir. Önerilen KSA yapısının temel blokları Şekil 4.4'te verildiği gibidir. İlk olarak giriş görüntüsü belirlenen boyut ve sayıdaki konvolüsyon filtrelerinden geçirilerek özellik haritaları oluşturulur. Sonrasında bu haritaların boyutlarını azaltmak amacıyla havuzlama katmanında maksimum havuzlama işlemine tabi tutulur. Bu işlemler belirlenen katman derinliğince tekrar edilir ve son kısımda sınıflandırma katmanıyla istenilen sınıflara ayrıştırılır.



Şekil 4.4. Önerilen KSA yapısı blokları

Çalışmada öncelikle, mamogram görüntüleri oluşturulan KSA üzerinde eğitildi ve sınıflandırma çalışmaları gerçekleştirildi. Çalışmada kullanılan ağ parametreleri Çizelge 4.1'deki gibidir.

Çizelge 4.1. Problem için oluşturulan KSA yapısının parametreleri

Parametreler	Değerler
Konvolüsyon Katmanı_1	3x3 boyutunda 32 filtre
Havuzlama Katmanı_1	2x2 filtre
Konvolüsyon Katmanı_2	3x3 boyutunda 64 filtre
Havuzlama Katmanı_2	2x2 filtre
Konvolüsyon Katmanı_3	3x3 boyutunda 128 filtre
Havuzlama Katmanı_3	2x2 filtre
Konvolüsyon Katmanı_4	3x3 boyutunda 128 filtre
Havuzlama Katmanı_4	2x2 filtre
Tam Bağlantılı Katman	512
Adım Sayısı	100
Öğrenme Oranı	0.00002

Transfer öğrenimi, belirli bir görev için eğitilen bir modelin başka bir görev için başlangıç noktası olarak kullanıldığı bir makine öğrenimi tekniğidir. Bu çalışmada, öznetelik çıkarımı ve parametrelerin hassas ayarı olmak üzere iki farklı şekilde transfer öğrenimi gerçekleştirilmiştir. Öznetelik çıkarımında önceden eğitilmiş olan ağı konvolüsyon katmanları sabit tutulup sadece sınıflandırma katmanı ilgili probleme göre düzenlenir. Burada amaç önceki eğitim görevinde öğrenilen özelliklerin yapılacak olan eğitim için kullanılmasıdır. Parametrelerin hassas ayarı yapılarak gerçekleştirilen eğitimlerde ise öznetelik çıkarımından farklı olarak sınıflandırma katmanından önceki birkaç konvolüsyon katmanı yeniden eğitmek üzere çözülür ve yapılacak işleme göre ağırlık güncellemesi gerçekleştirilir. Diğer duruma göre eğitim süresi daha uzundur.

Çalışmada VGG-16, VGG-19 (Zisserman, 2015), MobileNet (Howard ve ark., 2017), ResNet50 (He ve ark., 2016), NasNetLarge (Zoph ve ark., 2018), InceptionResNetV2 (Szegedy ve ark., 2017) modelleri kullanılarak transfer öğrenimi gerçekleştirilmiştir. VGG-16 ve VGG-19 yapıları AlexNet'ten esinlenerek geliştirilen KSA yapılarıdır. Burada, AlexNet'ten farklı olarak ağı derinliği VGG-16 için 16 katmanlı, VGG-19 için ise 19 katmanlıdır. Ayrıca bu modellerde kullanılan konvolüsyon filtrelerinin boyutları AlexNet'te kullanılanlara göre daha küçük boyutludur. MobileNet derinlemesine ayrılabilir konvolüsyonlar kullanarak ağı boyutunu ve hesaplanan parametreleri azaltmayı amaçlamaktadır. ResNet50, KSA sıklıkla karşılaşılan kaybolan eğitim (vanishing gradient) problemini çözmek amacıyla ağıda önceki öğrenilen özellikleri kullanarak artık (residual) katmanlar oluşturmaktadır. Burada amaç, daha derin ağların oluşturduğu bu problemi aşmak ve ağı daha verimli hale getirmektir.

Veri artırımı yapılarak oluşturulan veri setlerindeki görüntüler Çizelge 4.2'de belirtildiği üzere eğitim, doğrulama ve test aşamalarında kullanılmak üzere ayrılmıştır. Belirlenen veri sayıları önce KSA yapısı kullanılarak, sonrasında transfer öğrenimi için yukarıda bahsedilen modeller kullanılarak sınıflandırma çalışmalarında kullanılmıştır.

Çizelge 4.2. Eğitim, doğrulama ve test verisi sayıları

Görüntü Türü	Veri Sayısı		
	Eğitim	Doğrulama	Test
İyi Huylu	504	100	100
Kötü Huylu	372	100	100

Gerçekleştirilen çalışmada, mamogram görüntüleri üzerinde iyi huylu ve kötü huylu kitle sınıflandırması yapılmıştır. Eğitim öncesinde veri setinde ön işlemler gerçekleştirilerek temizlenmiş ve kesilmiş olmak üzere iki farklı veri seti oluşturulmuştur (Bölüm 3.1.1). Sınıflandırma için klasik bir KSA yapısı ve transfer öğrenimi ile farklı modeller kullanılarak eğitim işlemleri gerçekleştirilmiştir. Transfer öğrenimi modellerinin kullanımında öncelikle öznelik çıkarımı yöntemi kullanılmıştır. Bu işlemde, her ağın tüm konvolüsyon katmanları dondurulmuş ve sınıflandırma katmanı çalışmaya göre değiştirilmiştir. Ayrıca; sınıflandırma katmanında eğitim performansını iyileştirmek amacıyla seyreltme katmanı kullanılmıştır. Gerçekleştirilen eğitimler sonucunda kesilmiş ve temizlenmiş veri setleri üzerinde elde edilen eğitim, doğrulama ve test doğruluk oranları sırasıyla Çizelge 4.3 ve Çizelge 4.4'te verilmiştir. Çizelgelerde Klasik KSA olarak belirtilen yapı, problem için oluşturulan KSA modelini, belirtilen diğer ağ yapıları ise daha önce bahsedilen transfer öğrenme işlemleri için kullanılması ön görülen modelleri temsil etmektedirler.

Çizelge 4.3. MIAS temizlenmiş veri setinde öznelik çıkarımı yapılarak elde edilen sonuçlar

Kullanılan Ağ Yapısı	Temizlenmiş Veri Seti Doğruluk Oranları		
	Eğitim (%)	Doğrulama (%)	Test (%)
Klasik KSA	66.25	60	62
VGG-16(Zisserman, 2015)	97.2	74.5	69.4
VGG-19 (Zisserman, 2015)	93.49	65	60.5
MobileNet (Howard ve ark., 2017)	99.4	85	87.9
ResNet-50 (He ve ark., 2016)	61.1	53.5	52.9
NASNetLarge (Zoph ve ark., 2018)	99.6	81	82.9
Inception ResNetV2 (Szegedy ve ark., 2017)	99.3	84	85.5

Çizelge 4.4. MIAS kesilmiş veri setinde öznelik çıkarımı yapılarak elde edilen sonuçlar

Kullanılan Ağ Yapısı	Kesilmiş Veri Seti Doğruluk Oranları		
	Eğitim (%)	Doğrulama (%)	Test (%)
Klasik KSA	73.75	66	53
VGG-16 (Zisserman, 2015)	98.29	79	71.4
VGG-19 (Zisserman, 2015)	92.12	68.5	64.4
MobileNet (Howard ve ark., 2017)	100	85.5	73
ResNet-50 (He ve ark., 2016)	57.53	50	50
NASNetLarge (Zoph ve ark., 2018)	100	74.5	72.51
Inception ResNetV2 (Szegedy ve ark., 2017)	100	76.5	76.9

Çizelge 4.3 ve Çizelge 4.4 incelendiğinde kesilmiş veri seti kullanılarak elde edilen sonuçların temizlenmiş veri seti kullanılarak elde edilen sonuçlara göre daha yüksek doğruluk oranlarına sahip olduğu görülmektedir. Bunun sebebi olarak kesilmiş veri setinde temizlenmiş veri setinden farklı olarak sadece kitlelerin olduğu kısım eğitime dahil edilmiştir. Bu da kesilmiş veri seti ile gerçekleştirilen çalışmanın hem çalışma süresi olarak hem de doğruluk oranı olarak daha yüksek bir performans sergilemesine neden olmaktadır. KSA modeliyle diğer modelleri karşılaştırdığımızda transfer öğrenimi ile kullanılan modellerin daha yüksek doğruluk oranlarına ulaştığı açıkça görülmektedir. Bu modeller arasında MobileNet, NASNetLarge ve Inception ResNetV2 ağları kullanılan her iki veri setinde de en iyi performansı sergilemişlerdir. ResNet-50 ağı ise bu çalışmada en kötü sonuçlar elde edilen ağ olmuştur.

İkinci kısımda bu kez parametrelerin hassas ayarlanması işlemi gerçekleştirilerek eğitim işlemleri yapılmıştır. Burada öznetelik çıkarımından farklı olarak sınıflandırma katmanının yanı sıra bu katmandan önceki birkaç konvolüsyon katmanı çözülerek ağırlıklarının sınıflandırma katmanıyla birlikte yeniden güncellenmesi gerçekleştirilir. Bu işlem çözülen katmanlardaki ağırlıkların da yeniden güncellenmesini gerektirdiğinden daha fazla parametre eğitime sebep olur ve dolayısıyla ilk kısma göre eğitim süresinin uzamasına neden olur. Kesilmiş ve temizlenmiş veri setleri üzerinde gerçekleştirilen eğitimler sonucunda elde edilen eğitim, doğrulama ve test doğruluk oranları sırasıyla Çizelge 4.5 ve Çizelge 4.6’da verilmiştir.

Çizelge 4.5. MIAS temizlenmiş veri setinde hassas ayar yapılarak elde edilen sonuçlar

Kullanılan Ağ Yapısı	Temizlenmiş Veri Seti Doğruluk Oranları		
	Eğitim (%)	Doğrulama (%)	Test (%)
Klasik KSA	66.25	60	62
VGG-16 (Zisserman, 2015)	78.75	77	76
VGG-19 (Zisserman, 2015)	67.5	67	75.5
MobileNet (Howard ve ark., 2017)	71.2	66	79.5
ResNet-50 (He ve ark., 2016)	81.2	79	77
NASNetLarge (Zoph ve ark., 2018)	68.7	70	72
Inception ResNetV2 (Szegedy ve ark., 2017)	70	60.5	59

Çizelge 4.6. MIAS kesilmiş veri setinde hassas ayar yapılarak elde edilen sonuçlar

Kullanılan Ağ Yapısı	Kesilmiş Veri Seti Doğruluk Oranları		
	Eğitim (%)	Doğrulama (%)	Test (%)
Klasik KSA	73.75	66	53
VGG-16 (Zisserman, 2015)	100	89	80.5
VGG-19 (Zisserman, 2015)	73.75	68	70
MobileNet (Howard ve ark., 2017)	75	79	72.5
ResNet-50 (He ve ark., 2016)	80	76	80.5
NASNetLarge (Zoph ve ark., 2018)	66.25	62	72
Inception ResNetV2 (Szegedy ve ark., 2017)	65	58	60.5

Çizelge 4.5 ve Çizelge 4.6 incelendiğinde; hassas ayar yapılarak gerçekleştirilen transfer öğreniminde VGG-16 ve ResNet-50 ağlarının performanslarında yükseliş, diğer ağların performanslarında ise gözle görülür bir düşüş gözlemlenmiştir.

Çalışma sonucunda, öznetelik çıkarımı yapılarak gerçekleştirilen eğitimlerde MobileNet, NASNetLarge ve Inception ResNetV2 ağları, hassas parametre ayarı yapılarak gerçekleştirilen eğitimlerde ise ResNet-50 ağı en başarılı sonuçları vermiştir. Buradan uygulanan farklı transfer öğrenimi yöntemlerinin her modelde farklı sonuçlar verdiği, yapılan çalışmalar neticesinde kesilmiş veri setinin temizlenmiş veri setine göre çalışma performansını daha yukarı taşıdığı gözlemlenmiştir.


Çizelge 4.7’de gerçekleştirilen çalışma ile literatürde yer alan mamografi çalışmalarının karşılaştırılmasına yer verilmiştir. Burada, Guan ve ark. (Guan ve Loew, 2017) ile Duraisamy ve ark. (Duraisamy ve Emperumal, 2017) çalışmalarında normal mamografi görüntüleri ile kitle bulunan mamografi görüntülerini karşılaştırmışlar ve kitle tespiti çalışması gerçekleştirmişlerdir. Sun ve ark. (Sun ve ark., 2019) ise tez çalışmasındakine benzer şekilde iyi ve kötü huylu kitle karakterizasyonu çalışması gerçekleştirmişlerdir. Çizelge 4.7’de verilen sonuçlar karşılaştırıldığında yapılan çalışmada elde edilen doğruluk oranının (Sun ve ark., 2019) tarafından yapılan çalışmaya göre daha başarılı olduğu görülmüştür.

Çizelge 4.7. Literatürdeki çalışmaların sonuçları ile karşılaştırma

Literatürdeki Çalışmalar	Sınıflandırma Problemi	Test Verisi Doğruluk Oranları (%)
(Guan ve Loew, 2017)	Kitle Tespiti	90
(Duraisamy ve Emperumal, 2017)	Kitle Tespiti	99
(Sun ve ark., 2019)	Kitle karakterizasyonu	63
Yapılan Çalışma	Kitle karakterizasyonu	87

4.2.2. Kapsül ağlar kullanılarak gerçekleştirilen sınıflandırma çalışması

Kapsül ağlar, KSA yerine önerilen derin öğrenme ağ yapılarından birisidir. Metotlar bölümünde detaylı bir şekilde iç yapısı ve çalışma mantığı incelenmiştir. Bir önceki bölümde KSA kullanılarak gerçekleştirilen mamografi sınıflandırma çalışmaları bu bölümde önerilen kapsül ağ yapısı kullanılarak gerçekleştirilmiştir. Kullanılan kapsül ağ modeli Şekil 4.5'te verilmiştir.



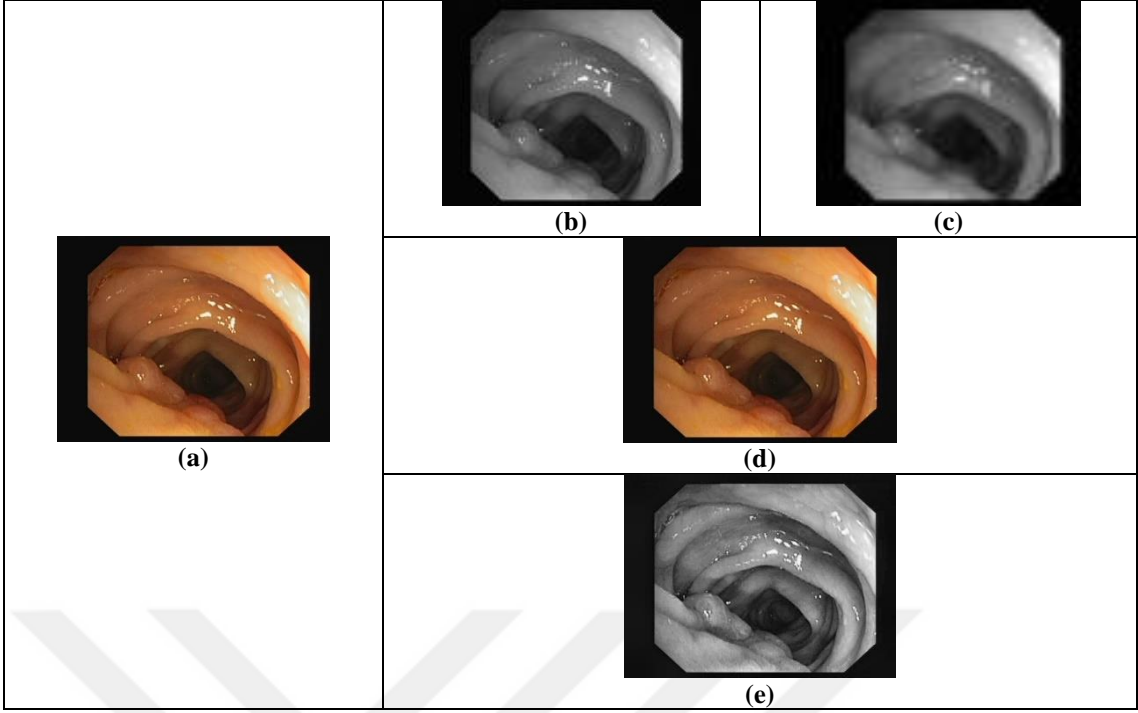
Şekil 4.5. MIA Sınıflandırma Kapsül Ağı

Bu aşamada veri setindeki görüntüleri eğitim ve test için manuel olarak ayırmak yerine 10-kat çapraz doğrulama (ÇD) kullanarak ayırma yoluna gidilmiştir. Çapraz doğrulama hem veri seti ayırma sırasında meydana gelen düzensizliği ortadan kaldırmakta hem de her bir verinin hem eğitim hem de test için ayrı ayrı kullanıldığında elde edilen sonuçların ortalamasını verdiği için çalışma doğruluğu açısından güven vermektedir. Şekil 4.6'da 10-kat çapraz doğrulamaya dair görsel verilmiştir. Burada; 10 parçaya ayrılan verinin 1 parçası test için, geri kalan 9 parçadan da %20'lik bir dilim doğrulama için ayrılmaktadır. Doğrulama ve test için ayrılan veriler dışında kalan

büyümesini ve ilerlemesini izlemeye yardımcı olabilir ve uygun tedavi seçeneklerinin seçilmesine yardımcı olabilir. Üçüncü olarak, segmentasyon poliplerin otomatik olarak tespit ve teşhis edilmesine yardımcı olabilir, bu da verimliliği artırabilir ve tıbbi görüntüleme analizindeki hataları azaltabilir.

4.3.1. U-Net modelleriyle yapılan segmentasyon çalışmaları

Bu bölümde, kapsamlı bir polip segmentasyonu çalışması gerçekleştirilmiştir. İlk olarak çalışma performansını artırmak amacıyla CVC-Clinic DB veri setine farklı ön işlemler (ADD, AKD, KSUHE) uygulanmıştır. Şekil 4.7 (a)'da verilen orijinal polip görüntüsüne ADD uygulandıktan sonra elde edilen 1. ve 2. seviye görüntüler Şekil 4.7 (b) ve Şekil 4.7 (c)'de sırasıyla verilmiştir. Görüntüye AKD uygulandıktan sonra elde edilen görüntü Şekil 4.7 (d)'de verilmiştir. Görüntüye KSUHE uygulandıktan sonra elde edilen görüntü Şekil 4.7 (e)'de verilmiştir. Sonrasında bu veri setleriyle orijinal U-Net ve modifiye edilmiş U-Net (Dice Kaybı) modelleri eğitilmiştir. Sonrasında modifiye U-Net modelinin kodlayıcı kısmı VGG16 ve VGG19 modelleriyle değiştirilerek çalışmalar gerçekleştirilmiştir. Tüm bu işlemler gerçekleştirilirken k-kat ÇD ve yığın boyutları kullanılmıştır. Elde edilen sonuçlar neticesinde kullanılan derin ağ modelleri en iyi sonucu veren ÇD değerinde farklı yığın boyutlarıyla ve farklı veri setleriyle (Etis-Larib (Silva ve ark., 2014), Kvasir-Seg (Jha ve ark., 2020)) test edilmiştir. Ayrıca en iyi sonucu veren veri seti ve ÇD değeri kullanılarak farklı kayıp fonksiyonları ve en son modellerle çalışma karşılaştırılmıştır.



Şekil 4.7. a) Orijinal Polip Görüntüsü b) İlk seviye ADD uygulandıktan sonra elde edilen görüntü c) İkinci seviye ADD uygulandıktan sonra elde edilen görüntü d) AKD uygulandıktan sonra elde edilen görüntü e) KSUHE uygulandıktan sonra elde edilen görüntü

Ham veri seti, ADD, AKD ve KSUHE uygulanmış veri setleri olmak üzere toplamda dört veri seti sırasıyla orijinal U-Net, modifiye edilmiş U-Net, VGG-16 ile modifiye edilmiş U-Net ve VGG-19 ile modifiye edilmiş U-Net ağları ile eğitilmiştir. Eğitimlerde kullanılan öğrenme oranı 10^{-4} olarak belirlenmiş ve her 3 döngüde herhangi bir ilerleme kaydedilmediğinde öğrenme oranı %10 oranında düşürülmüştür. Eğitimler 1000 döngü boyunca devam etmiştir. Eğitimde, veri setini ayırmadaki dengesizliği en aza indirmek için k-kat ÇD kullanılmıştır. k değeri olarak 2, 3 ve 4 seçilmiştir. Ayrıca çalışmada 1'den 5'e kadar farklı yığın boyutları kullanılarak modellerin duyarlılık analizi yapılmıştır. Ağ eğitiminde 612 veri içeren CVC Clinic DB veri seti k-kat ÇD'daki k sayısına göre eğitim ve test verisi olarak ikiye ayrılır. Eğitim için ayrılan verilerin %10'u da doğrulama için ayrılmıştır. Farklı k değerleri için tahsis edilen eğitim, doğrulama ve test verisi sayıları Çizelge 4.9'da verilmiştir. Eğitim için ayrılan görüntülere ezberlemeyi engellemek amacıyla farklı veri artırımı teknikleri uygulanmıştır.

Çizelge 4.9. Eğitim, doğrulama ve test için ayrılan görüntü sayıları

k değeri	Eğitim	Doğrulama	Test
2	275	31	306
3	367	41	204
4	413	46	153

Çalışmanın ilk kısmında, orijinal U-Net modeli kullanılarak farklı ön işlemler uygulanmış veri setleriyle, farklı k-kat ve yığın değerleri için sonuçlar elde edilmiştir. Kullanılan ağ yapısı Şekil 3.14’te verildiği gibidir. Burada kodlayıcı kısmında her bir katmanda sırasıyla (64, 128, 256, 512) konvolüsyon filtresi kullanılmıştır. Kod çözücü kısmında ise aşağıdan yukarıya doğru (512, 256, 128, 64) filtre kullanılmıştır. Dar boğaz kısmında ise 1024 filtre kullanılmıştır. Görüntü boyutu olarak 64 x 64 görüntü boyutunda çalışılmıştır. Bu model için elde edilen test sonuçları Çizelge 4.10’ da verilmiştir.

Çizelge 4.10 incelendiğinde; her bir k değeri için en iyi sonuçların ADD uygulanmış görüntüler ile elde edildiği görülmektedir. Bu veri setinde k=2 ve yığın boyutu 1 için DK, JO, DUY, ÖZG sırasıyla 0.794, 0.711, 0.803, 0.992, k=3 ve yığın boyutu 1 için DK, JO, DUY, ÖZG sırasıyla 0.832, 0.752, 0.839, 0.992, k=4 ve yığın boyutu 2 için DK, JO, DUY, ÖZG sırasıyla 0.835, 0.756, 0.840, 0.992 olarak elde edilmiştir. Bunların içerisinde en iyi sonuçlara k=4 ve yığın boyutu 2 seçildiğinde ulaşılmıştır.

Çizelge 4.10. Orijinal U-Net modeli ile polip segmentasyonu ortalama test sonuçları

Yığın Boyutu	Metrik	HAM			ADD			AKD			KSUHE		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.791	0.823	0.821	0.794	0.832	0.826	0.787	0.817	0.828	0.674	0.696	0.694
	JO	0.705	0.737	0.739	0.711	0.752	0.749	0.699	0.731	0.746	0.545	0.565	0.565
	DUY	0.810	0.835	0.836	0.803	0.839	0.749	0.803	0.821	0.838	0.805	0.833	0.565
	ÖZG	0.991	0.991	0.992	0.992	0.992	0.993	0.990	0.992	0.992	0.991	0.991	0.992
2	DK	0.787	0.816	0.822	0.792	0.825	0.835	0.790	0.823	0.825	0.669	0.691	0.689
	JO	0.698	0.730	0.735	0.710	0.745	0.756	0.702	0.737	0.739	0.539	0.562	0.560
	DUY	0.806	0.824	0.829	0.710	0.835	0.840	0.817	0.838	0.837	0.804	0.829	0.826
	ÖZG	0.990	0.992	0.992	0.913	0.992	0.992	0.990	0.991	0.992	0.990	0.992	0.992
3	DK	0.783	0.810	0.817	0.793	0.815	0.830	0.783	0.816	0.821	0.668	0.692	0.688
	JO	0.694	0.721	0.730	0.707	0.732	0.748	0.694	0.729	0.821	0.540	0.560	0.559
	DUY	0.798	0.829	0.827	0.801	0.820	0.839	0.799	0.829	0.845	0.801	0.824	0.831
	ÖZG	0.991	0.990	0.992	0.992	0.992	0.992	0.990	0.991	0.991	0.991	0.992	0.991
4	DK	0.777	0.693	0.821	0.790	0.828	0.826	0.776	0.813	0.809	0.663	0.692	0.689
	JO	0.685	0.562	0.733	0.705	0.744	0.744	0.682	0.724	0.723	0.534	0.562	0.559
	DUY	0.796	0.834	0.833	0.811	0.836	0.831	0.798	0.827	0.826	0.800	0.832	0.826
	ÖZG	0.990	0.991	0.992	0.991	0.992	0.831	0.989	0.991	0.991	0.990	0.991	0.991
5	DK	0.768	0.812	0.812	0.777	0.816	0.820	0.777	0.811	0.811	0.666	0.685	0.688
	JO	0.671	0.724	0.725	0.685	0.730	0.737	0.684	0.721	0.723	0.538	0.555	0.559
	DUY	0.791	0.826	0.828	0.798	0.821	0.837	0.792	0.824	0.829	0.799	0.821	0.835
	ÖZG	0.988	0.992	0.991	0.989	0.992	0.992	0.991	0.991	0.991	0.990	0.991	0.991

Çalışmanın bir sonraki aşamasında orijinal U-Net modelinde kullanılan kayıp fonksiyonu İÇE kaybı yerine “Dice Kaybı” kullanılarak bir modifiye edilmiş U-Net yapısı elde edilmiştir. Bu model için de bir önceki aşamada kullanılan veri setleri, k-kat sayıları ve yığın boyutları kullanılmıştır. Bu modelin eğitimi sonucu elde edilen test sonuçları Çizelge 4.11’de görüldüğü gibidir.

Çizelge 4.11 incelendiğinde; k=2 değeri için en iyi sonuçların AKD uygulanmış görüntülerle, diğer k değerleri içinse ADD uygulanmış görüntülerle elde edildiği görülmektedir. AKD veri setinde k=2 ve yığın boyutu 1 için DK, JO, DUY, ÖZG sırasıyla 0.838, 0.760, 0.852, 0.992, ADD veri setinde k=3 ve yığın boyutu 1 için DK, JO, DUY, ÖZG sırasıyla 0.865, 0.796, 0.872, 0.993, aynı veri setinde k=4 ve yığın boyutu 1 için DK, JO, DUY, ÖZG sırasıyla 0.868, 0.799, 0.873, 0.994 olarak elde edilmiştir. Bunların içerisinde en iyi sonuçlara ADD veri setinde k=4 ve yığın boyutu 1 seçildiğinde ulaşılmıştır.

Çizelge 4.11. Modifiye edilmiş U-Net modeli ile polip segmentasyonu ortalama test sonuçları

Yığın Boyutu	Metrik	HAM			ADD			AKD			KSUHE		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.835	0.858	0.857	0.833	0.865	0.868	0.838	0.857	0.859	0.755	0.781	0.778
	JO	0.758	0.785	0.784	0.760	0.796	0.799	0.760	0.783	0.787	0.644	0.671	0.667
	DUY	0.850	0.873	0.877	0.840	0.872	0.873	0.852	0.868	0.871	0.847	0.882	0.874
	ÖZG	0.992	0.993	0.993	0.992	0.993	0.994	0.992	0.993	0.993	0.991	0.992	0.992
2	DK	0.826	0.849	0.864	0.831	0.856	0.862	0.825	0.847	0.855	0.760	0.775	0.779
	JO	0.748	0.775	0.791	0.756	0.786	0.793	0.748	0.773	0.783	0.647	0.663	0.668
	DUY	0.845	0.854	0.879	0.839	0.859	0.876	0.845	0.859	0.875	0.853	0.867	0.884
	ÖZG	0.991	0.993	0.992	0.991	0.993	0.992	0.990	0.993	0.993	0.991	0.991	0.992
3	DK	0.813	0.845	0.849	0.825	0.855	0.858	0.820	0.848	0.852	0.752	0.771	0.776
	JO	0.732	0.770	0.775	0.749	0.783	0.786	0.740	0.771	0.779	0.639	0.660	0.665
	DUY	0.823	0.858	0.856	0.831	0.857	0.866	0.832	0.864	0.869	0.836	0.868	0.875
	ÖZG	0.990	0.992	0.993	0.991	0.993	0.992	0.991	0.992	0.993	0.991	0.990	0.992
4	DK	0.813	0.842	0.844	0.822	0.848	0.859	0.826	0.838	0.846	0.753	0.765	0.773
	JO	0.732	0.766	0.768	0.746	0.776	0.788	0.747	0.764	0.770	0.642	0.655	0.664
	DUY	0.829	0.857	0.853	0.836	0.851	0.863	0.840	0.844	0.849	0.852	0.859	0.874
	ÖZG	0.991	0.992	0.993	0.989	0.992	0.993	0.991	0.993	0.993	0.991	0.992	0.992
5	DK	0.816	0.846	0.845	0.815	0.841	0.844	0.816	0.840	0.843	0.736	0.766	0.767
	JO	0.736	0.771	0.771	0.738	0.766	0.772	0.736	0.765	0.767	0.625	0.655	0.656
	DUY	0.827	0.857	0.862	0.820	0.844	0.845	0.838	0.851	0.860	0.827	0.860	0.864
	ÖZG	0.991	0.992	0.993	0.990	0.991	0.991	0.989	0.992	0.992	0.990	0.991	0.991

Çalışmanın bir sonraki aşamasında transfer öğrenmenin etkisini gözlemlemek amacıyla U-Net'in kodlayıcı kısmında VGG-16 ve VGG-19 ağları kullanılarak çalışmalar gerçekleştirilmiştir. İlk olarak kodlayıcı kısımda VGG-16 ağı kullanılan modelin eğitimi sonucunda elde edilen sonuçlar Çizelge 4.12'de verilmiştir.

Çizelge 4.12 incelendiğinde; tüm k değerleri için en iyi sonuçların ADD uygulanmış görüntülerle ve yığın boyutu 1 seçildiğinde elde edildiği görülmektedir. Bu veri setinde en iyi sonuçlar k=2 için DK, JO, DUY, ÖZG sırasıyla 0.785, 0.697, 0.790, 0.990, k=3 için DK, JO, DUY, ÖZG sırasıyla 0.824, 0.744, 0.832, 0.991, k=4 için DK, JO, DUY, ÖZG sırasıyla 0.825, 0.748, 0.820, 0.992 olarak elde edilmiştir. Bunların içerisinde en iyi sonuçların k=4 ve yığın boyutu 1 seçildiğinde elde edildiği görülmektedir.

Çizelge 4.12. Kodlayıcı kısmı VGG-16 ile modifiye edilmiş U-Net modeli ile polip segmentasyonu ortalama test sonuçları

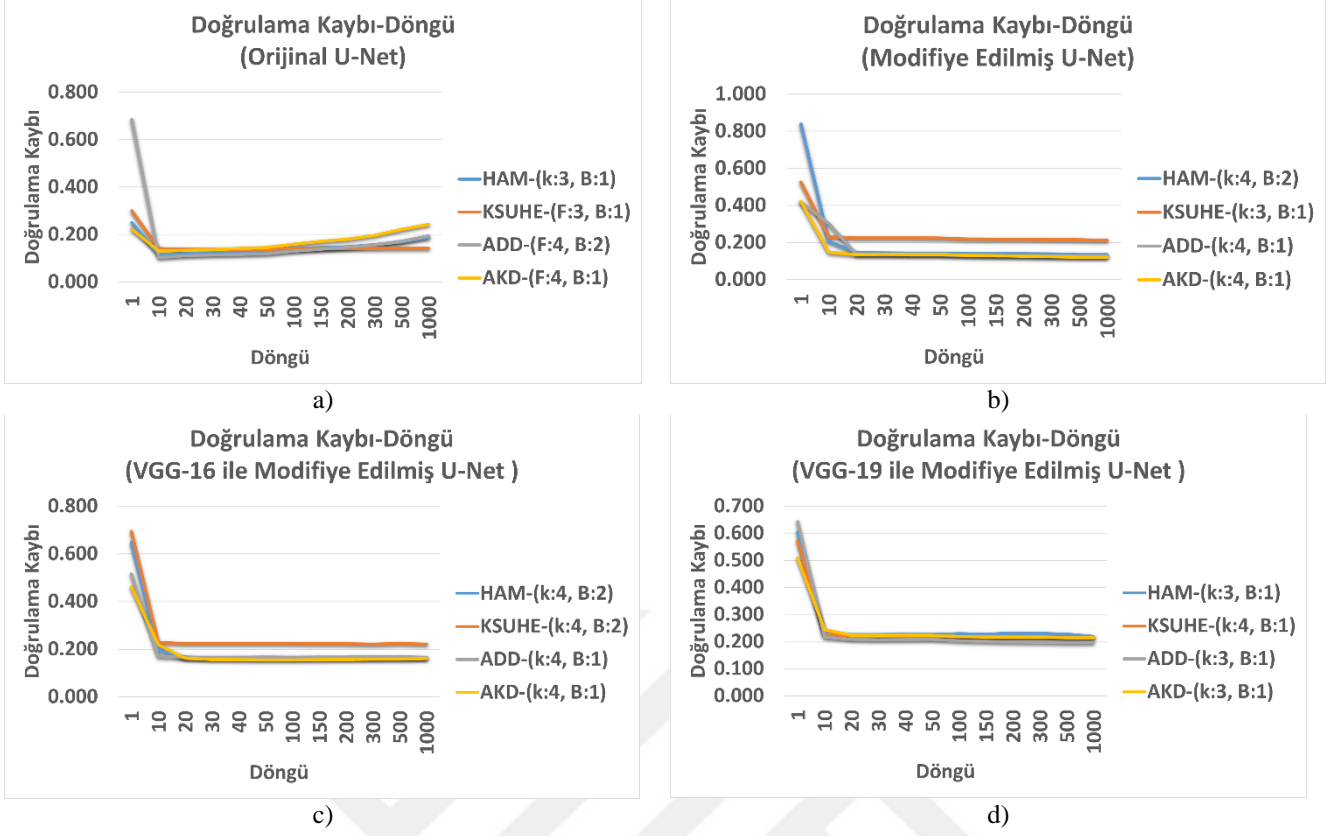
Yığın Boyutu	Metrik	HAM			ADD			AKD			KSUHE		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.782	0.810	0.814	0.785	0.824	0.825	0.777	0.811	0.814	0.726	0.754	0.754
	JO	0.694	0.726	0.733	0.697	0.744	0.748	0.684	0.726	0.731	0.611	0.640	0.641
	DUY	0.798	0.828	0.827	0.790	0.832	0.820	0.797	0.825	0.817	0.809	0.842	0.846
	ÖZG	0.991	0.991	0.991	0.990	0.991	0.992	0.989	0.991	0.992	0.991	0.992	0.992
2	DK	0.771	0.795	0.815	0.774	0.815	0.819	0.765	0.803	0.803	0.730	0.742	0.758
	JO	0.680	0.707	0.731	0.684	0.735	0.740	0.672	0.717	0.718	0.615	0.627	0.643
	DUY	0.788	0.808	0.829	0.774	0.819	0.823	0.783	0.817	0.812	0.808	0.838	0.845
	ÖZG	0.989	0.991	0.991	0.990	0.992	0.992	0.989	0.991	0.992	0.991	0.990	0.992
3	DK	0.765	0.795	0.803	0.769	0.810	0.810	0.760	0.787	0.803	0.708	0.741	0.757
	JO	0.671	0.707	0.719	0.681	0.728	0.730	0.668	0.699	0.718	0.591	0.626	0.643
	DUY	0.791	0.815	0.812	0.774	0.817	0.816	0.781	0.802	0.821	0.796	0.833	0.851
	ÖZG	0.988	0.990	0.992	0.989	0.991	0.992	0.988	0.990	0.991	0.989	0.990	0.991
4	DK	0.760	0.791	0.802	0.763	0.806	0.812	0.736	0.788	0.803	0.716	0.738	0.748
	JO	0.663	0.700	0.717	0.668	0.722	0.730	0.640	0.700	0.715	0.600	0.623	0.634
	DUY	0.779	0.812	0.820	0.771	0.817	0.821	0.771	0.807	0.819	0.805	0.824	0.845
	ÖZG	0.988	0.989	0.990	0.987	0.990	0.991	0.986	0.990	0.990	0.990	0.991	0.990
5	DK	0.738	0.789	0.800	0.758	0.810	0.812	0.740	0.793	0.808	0.712	0.730	0.752
	JO	0.643	0.702	0.711	0.666	0.725	0.730	0.643	0.705	0.721	0.594	0.615	0.637
	DUY	0.765	0.807	0.825	0.783	0.821	0.824	0.767	0.817	0.822	0.802	0.824	0.844
	ÖZG	0.987	0.990	0.989	0.986	0.989	0.990	0.987	0.989	0.991	0.988	0.990	0.991

Kodlayıcı kısımda VGG-19 kullanılan U-Net modeliyle gerçekleştirilen eğitimler sonucunda elde edilen ortalama test sonuçları Çizelge 4.13'te verilmiştir. Çizelge incelendiğinde; k=2 değeri için en iyi sonuçların AKD uygulanmış görüntülerle, diğer k değerleri içinse ADD uygulanmış görüntülerle ve her bir k değeri için yığın boyutu 1 seçildiğinde elde edildiği görülmektedir. AKD veri setinde k=2 için DK, JO, DUY, ÖZG sırasıyla 0.757, 0.665, 0.783, 0.987, ADD veri setinde k=3 için DK, JO, DUY, ÖZG sırasıyla 0.808, 0.728, 0.820, 0.992, aynı veri setinde k=4 için DK, JO, DUY, ÖZG sırasıyla 0.806, 0.725, 0.807, 0.992 olarak elde edilmiştir. Bunların içerisinde en iyi sonuçlara ADD veri setinde k=3 ve yığın boyutu 1 seçildiğinde ulaşılmıştır.

Çizelge 4.13. Kodlayıcı kısmı VGG-19 ile modifiye edilmiş U-Net modeli ile polip segmentasyonu ortalama test sonuçları

Yığın Boyutu	Metrik	HAM			ADD			AKD			KSUHE		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.756	0.803	0.795	0.756	0.808	0.806	0.757	0.805	0.801	0.728	0.757	0.759
	JO	0.660	0.715	0.709	0.669	0.728	0.725	0.665	0.721	0.715	0.613	0.643	0.646
	DUY	0.775	0.823	0.807	0.767	0.820	0.807	0.783	0.815	0.807	0.810	0.852	0.854
	ÖZG	0.987	0.990	0.992	0.990	0.992	0.992	0.987	0.991	0.991	0.990	0.991	0.992
2	DK	0.741	0.786	0.798	0.748	0.794	0.805	0.751	0.791	0.803	0.727	0.739	0.747
	JO	0.645	0.695	0.711	0.653	0.708	0.722	0.655	0.702	0.717	0.612	0.623	0.633
	DUY	0.773	0.804	0.816	0.759	0.808	0.813	0.767	0.813	0.811	0.819	0.824	0.838
	ÖZG	0.986	0.989	0.991	0.987	0.989	0.990	0.988	0.989	0.991	0.988	0.991	0.991
3	DK	0.736	0.791	0.783	0.729	0.795	0.791	0.737	0.777	0.79	0.707	0.744	0.749
	JO	0.637	0.698	0.694	0.633	0.707	0.705	0.639	0.683	0.701	0.587	0.627	0.634
	DUY	0.774	0.812	0.792	0.732	0.805	0.794	0.768	0.794	0.809	0.801	0.830	0.846
	ÖZG	0.985	0.988	0.99	0.988	0.989	0.989	0.986	0.988	0.989	0.987	0.991	0.990
4	DK	0.727	0.772	0.783	0.729	0.798	0.783	0.722	0.783	0.783	0.704	0.733	0.744
	JO	0.623	0.678	0.694	0.632	0.708	0.699	0.617	0.693	0.696	0.585	0.618	0.629
	DUY	0.755	0.788	0.813	0.752	0.810	0.792	0.751	0.804	0.798	0.798	0.823	0.835
	ÖZG	0.985	0.988	0.988	0.985	0.990	0.989	0.983	0.988	0.99	0.987	0.989	0.990
5	DK	0.719	0.78	0.768	0.708	0.785	0.785	0.728	0.78	0.772	0.696	0.735	0.737
	JO	0.620	0.687	0.676	0.605	0.693	0.696	0.625	0.689	0.679	0.579	0.619	0.623
	DUY	0.752	0.799	0.799	0.732	0.801	0.795	0.756	0.798	0.790	0.791	0.831	0.830
	ÖZG	0.984	0.988	0.987	0.984	0.988	0.988	0.984	0.989	0.988	0.987	0.990	0.990


Segmentasyon çalışmasında kullanılan modellerin karşılaştırmalı analizi için her bir veri setinde en iyi sonuçların elde edildiği ÇD-yığın boyutu değerleri için doğrulama kaybı-döngü grafikleri çizilmiş ve Şekil 4.8’de sunulmuştur. Grafiklerde mavi ile gösterilen çizgi ham veri setini, turuncu ile gösterilen çizgi KSUHE uygulanmış veri setini, gri ile gösterilen çizgi ADD uygulanmış veri setini ve sarı ile gösterilen çizgi AKD uygulanmış veri setini ifade etmektedir. Aynı zamanda bu veri setlerinin hangi ÇD-yığın boyutu çiftinde en iyi sonuçları verdiği grafik lejantında belirtilmektedir. Burada k, ÇD kat sayısını, B ise yığın boyutunu belirtmektedir. Grafiklerden açıkça görülebileceği gibi modifiye edilmiş U-Net (Dice Kaybı) modelinin kayıp değeri diğer modellere göre en küçük değere sahiptir. Bu da doğrulama kaybı açısından en başarılı model olduğunu göstermektedir.



Şekil 4.8. Doğrulama kaybı-döngü grafikleri.

a) Orijinal U-Net modeli için doğrulama kaybı-döngü grafiği **b)** Modifiye edilmiş U-Net modeli için doğrulama kaybı-döngü grafiği **c)** VGG-16 ile modifiye edilmiş U-Net modeli için doğrulama kaybı-döngü grafiği **d)** VGG-19 ile modifiye edilmiş U-Net modeli için doğrulama kaybı-döngü grafiği

Yapılan uygulamalar sonucunda tüm modellerde genel olarak ADD uygulanan veri setiyle yapılan çalışmalar en iyi sonuçları vermiştir. Buradan da ADD'nin kullanılan polip veri setinde diğerlerine nazaran daha üstün bir ön işleme yöntemi olduğu görülmektedir. Çalışmanın geneli itibarıyla, en iyi sonuçlar modifiye edilmiş U-Net (Dice Kaybı) modelinde 4-kat ÇD kullanıldığında elde edilmiştir. Bu ÇD değeri için elde edilen sonuçların grafiksel gösterimi Şekil 4.9'da verilmiştir.



Şekil 4.9. 4-kat ÇD ve modifiye edilmiş U-Net ile polip segmentasyon sonuçları

Önerilen modelin farklı veri setlerinde üzerindeki performansını gözlemlemek amacıyla Kvasir-Seg ve ETIS-Larib veri setleri üzerinde de segmentasyon çalışmaları gerçekleştirilmiştir. Yapılan çalışmalarda önceki çalışmalarda en iyi sonucu veren 4-kat ÇD kullanılmış ve farklı yığın boyutları için eğitimler gerçekleştirilmiştir. Elde edilen sonuçlar Çizelge 4.14’te verilmiştir. Kvasir-Seg veri seti için en iyi sonuca yığın boyutu 3 seçildiğinde DK, JO, DUY, ÖZG, HD sırasıyla 0.642, 0.537, 0.514, 0.975 ve 4.223 mm olarak ulaşılmıştır. ETIS-Larib veri setinde ise optimum sonuçlara yığın boyutu 1 seçildiğinde DK, JO, DUY, ÖZG, HD sırasıyla 0.392, 0.320, 0.615, 0.969 ve 5.614 mm olarak elde edilmiştir.

Çizelge 4.14. Kvasir-Seg ve ETIS-Larib veri setleri ile polip segmentasyonu ortalama test sonuçları

Veri Seti	Yığın Boyutu	DK	JO	DUY	ÖZG	HM (mm)
Kvasir-Seg	1	0.637	0.536	0.495	0.980	3.919
	2	0.625	0.525	0.490	0.979	4.159
	3	0.642	0.537	0.514	0.975	4.223
	4	0.624	0.521	0.487	0.978	4.389
	5	0.615	0.512	0.484	0.977	4.494
ETIS-Larib	1	0.392	0.320	0.615	0.969	5.614
	2	0.356	0.288	0.563	0.964	6.302
	3	0.370	0.297	0.607	0.957	6.455
	4	0.343	0.276	0.552	0.959	6.421
	5	0.352	0.280	0.591	0.959	6.555

Çalışmanın doğruluğunu test etmek amacıyla literatürde önerilen en son (state-of-the-art) modellerden birisi olan U-Net++ (Zhou ve ark., 2018) modeliyle ADD uygulanan veri setinde ve 4-kat ÇD değerinde farklı yığın boyutlarında eğitimler gerçekleştirilmiştir. Çizelge 4.15'te yapılan eğitimler sonucunda elde edilen ortalama test sonuçlarına yer verilmiştir. Çizelgede diğer performans metriklerine ek olarak HD metriği de eklenmiştir. Açıkça görüleceği üzere en iyi sonuçlara yığın boyutu 1 seçildiğinde DK, JO, DUY, ÖZG, HD sırasıyla 0.804, 0.725, 0.805, 0.992 ve 1.821 mm olarak elde edilmiştir.

Çizelge 4.15. U-Net++ modeli ile polip segmentasyonu ortalama test sonuçları

Yığın Boyutu	DK	JO	DUY	ÖZG	HM (mm)
1	0.804	0.725	0.805	0.992	1.821
2	0.797	0.717	0.799	0.992	2.079
3	0.797	0.714	0.808	0.99	1.937
4	0.788	0.705	0.798	0.99	2.011
5	0.769	0.684	0.785	0.989	2.008


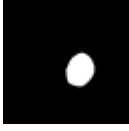

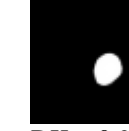


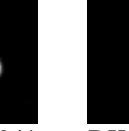
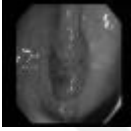






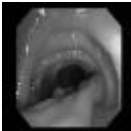






Yine çalışmanın güvenilirliğini test etmek amacıyla farklı kayıp fonksiyonları üzerinde U-Net eğitimleri gerçekleştirilmiştir. Bu zamana kadar yapılan çalışmalarda, 4-kat ÇD ve yığın boyutu 1 seçildiğinde en iyi sonuçların açık ara elde edildiği görüldüğünden dolayı bu aşamada sadece bu ÇD-yığın boyutu üzerinde eğitimler gerçekleştirilmiştir. Çizelge 4.16'da hem Focal kaybı hem de Focal-Tversky kaybı üzerinde yapılan çalışmalar sonucunda elde edilen test sonuçları verilmiştir. Çizelgede en iyi sonuçlar Focal-Tversky kaybı kullanılan modelde DK, JO, DUY, ÖZG, HM sırasıyla 0.853, 0.782, 0.872, 0.992 ve 4.65 mm olarak elde edilmiştir.

Çizelge 4.16. Farklı kayıp fonksiyonlarıyla yapılan polip segmentasyon çalışması ortalama test sonuçları

Kayıp Fonksiyonu	DK	JO	DUY	ÖZG	HM (mm)
Focal Kaybı	0.790	0.684	0.810	0.993	4.979
Focal-Tversky Kaybı	0.853	0.782	0.872	0.992	4.65

Çalışmada son olarak hem farklı kayıp fonksiyonları ile yapılan çalışmalarda hem de U-Net++ ile yapılan çalışmada elde edilen nitel sonuçlara yer verilmiştir. Burada, test görüntüleri üzerinde modellerin tahmin performansları incelenmiştir. Performansları nicel olarak değerlendirmek için de her bir tahmin görüntüsünün DK skoru hesaplanmıştır. Çizelge 4.17'de yapılan değerlendirmeler yer almaktadır. Çizelgeden de görüleceği üzere modifiye edilmiş U-Net modeli (Dice kaybı) diğerlerine nazaran en yüksek DK skoruna ulaşmıştır.

Çizelge 4.17. Polip segmentasyonu için test görüntüleri, gerçek maskeler ve tahmin görüntüleri (Tüm çalışmalar ADD veri setinde 4 kat ÇD, yığın boyutu 1 seçilerek yapılmıştır).

Test Görüntüleri	Gerçek Maske	Tahmin (U-Net++)	Tahmin (Orijinal U-Net)	Tahmin Modifiye Edilmiş U-Net (Dice Kaybı)	Tahmin Modifiye Edilmiş U-Net (Focal Kaybı)	Tahmin Modifiye Edilmiş U-Net (Focal-Tversky Kaybı)
		 DK = 0.953	 DK = 0.960	 DK = 0.957	 DK = 0.941	 DK = 0.951
		 DK = 0.956	 DK = 0.961	 DK = 0.971	 DK = 0.961	 DK = 0.961
		 DK = 0.959	 DK = 0.985	 DK = 0.985	 DK = 0.975	 DK = 0.977

Yapılan çalışmaların eski çalışmalarla kıyaslanması çalışma güvenilirliği ve doğruluğu açısından büyük önem arz etmektedir. Literatürde her çalışmada kullanılan performans metrikleri farklılık gösterdiğinden dolayı benzer kriterleri yakalamak için farklı metrikler kullanılmıştır. Karşılaştırılan tüm çalışmalarda CVC-Clinic DB (Bernal ve ark., 2015) veri seti kullanılmıştır. Böylece adil bir karşılaştırma yapmak mümkün hale gelmiştir. Çizelge 4.18’de bu çalışmada yer alan ve literatürdeki modellerin sonuçlarına yer verilmiştir. Çizelgeden de görüleceği üzere modeller arasında en iyi performansı modifiye edilmiş U-Net (Dice Kaybı) modeli göstermiştir.

Çizelge 4.18. Yapılan çalışmanın literatürdeki polip segmentasyonu çalışmalarıyla karşılaştırılması

Çalışma	Kullanılan Yöntem	DK	JO	DUY	ÖZG	HM (mm)
(Nguyen ve Lee, 2018)	Kodlayıcı-Kod Çözücü Ağ	0.829	0.842	-	-	-
(Brandao ve ark., 2017)	AlexNet, VGG, GoogLeNet	-	-	0.863	-	-
(Li ve ark., 2017a)	TKA ve U-Net	-	-	0.773	0.990	-
(Banik ve ark., 2020)	KSA	0.813	-	0.786	-	-
(Kang ve Gwak, 2019)	Mask R-CNN, ResNet50, ResNet101	-	0.694	0.762	-	-
*U-Net ++	U-Net ++	0.804	0.725	0.805	0.992	1.821
*U-Net (İÇE Kaybı)	U-Net	0.835	0.756	0.840	0.992	5.449
*U-Net (Focal Kaybı)	U-Net	0.790	0.684	0.810	0.993	4.979
*U-Net (Focal-Tversky Kaybı)	U-Net	0.853	0.782	0.872	0.992	4.650
*U-Net (Dice Kaybı)	U-Net	0.868	0.799	0.873	0.994	1.341

*Bu Çalışma

4.4. Abdomen Veri Setiyle Yapılan Çalışmalar

Adrenal tümörler, her böbreğin üzerinde bulunan adrenal bezde gelişen büyümelelerdir. Bu tümörler iyi huylu veya kötü huylu olabilirler. Yüksek tansiyon, kilo alımı ve hormonal dengesizlikler gibi çeşitli semptomlara neden olabilirler.

Adrenal tümörlerin doğru sınıflandırılması, iyi huylu mu yoksa kötü huylu mu olduklarının belirlenmesine yardımcı olabilir; bu da tedavi planlaması ve hastalığın ön görüsünün (prognoz) belirlenmesi için önemlidir.

Adrenal tümörlerin segmentasyonu da önemlidir çünkü klinisyenlerin tümörü görselleştirmesine olanak tanıyarak cerrahi planlama ve tedavi kararlarını yönlendirmeye yardımcı olabilir. Doğru segmentasyon, zaman içinde tümör büyümesini izlemek ve tedavi yanıtını değerlendirmek için önemli olan tümör boyutu ölçümlerinin doğruluğunu artırmaya da yardımcı olabilir.


Bu tez çalışması kapsamında, Selçuk Üniversitesi Tıp Fakültesi Radyoloji Anabilim dalından alınan T1 ve T2 ağırlıklı MR abdominal görüntüler üzerinde adrenal lezyon tespiti amacıyla segmentasyon ve adrenal lezyonların türünü (iyi huylu/ kötü huylu) sınıflandırmak için sınıflandırma çalışmaları gerçekleştirilmiştir. Yapılan segmentasyon ve sınıflandırma çalışmaları sırasıyla 4.4.1 ve 4.4.2'de verilmiştir.

4.4.1. Abdomen veri setiyle yapılan segmentasyon çalışması

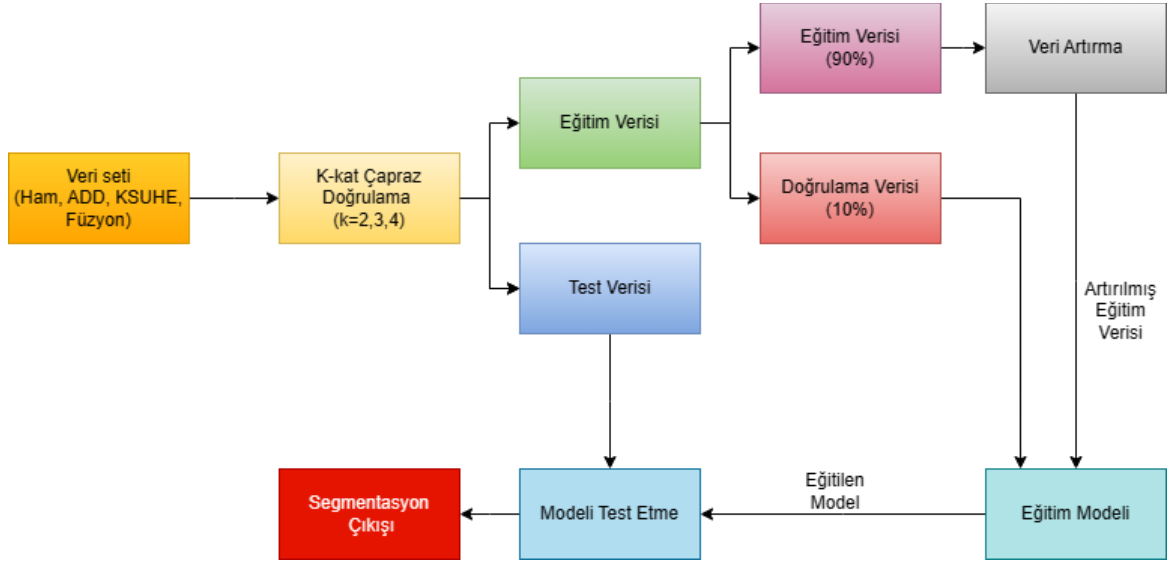
Çalışmada, abdomen görüntülerden adrenal tümör segmentasyonu için U-Net ve modifiye edilmiş U-Net modelleri kullanılmıştır. Eğitim ve test verilerinin ayrılması sırasında oluşan heterojenliği ortadan kaldırmak için k-kat çapraz doğrulama (k-kat ÇD) tercih edilmiştir. Çalışma sonucunda en iyi sonuçların alındığı veri seti, k-kat ÇD ve yığın boyutları için farklı modellerle eğitim gerçekleştirilmiş ve sonuçlar karşılaştırılmıştır.

Öncelikle mevcut veri seti U-Net modeli ile eğitilmiştir. Eğitim sırasında aşırı uydurmayı önlemek için veri çoğaltma (data augmentation) kullanılmıştır. Bunun için yükseklik kaydırma, yatay çevirme, döndürme, kesme, genişlik kaydırma ve yakınlaştırma yöntemleri kullanılmıştır. Şekil 4.11, veri çoğaltmadan sonra elde edilen örnek görüntüleri göstermektedir. Ek olarak, eğitim ve test için veri ayrımı sırasında heterojenliği ortadan kaldırmak için k-kat ÇD kullanılmıştır. Farklı k-kat değerlerinin çalışmayı nasıl etkilediğini gözlemlemek için eğitimler k=2, k=3 ve k=4 değerleri için tekrarlanmıştır. Aynı zamanda, yığın boyutunun eğitimdeki etkisini gözlemlemek için her

k-katlı ÇD için farklı yığın boyutlarında eğitimler gerçekleştirilmiştir. Eğitimler sırasında kullanılan yığın boyutları bir ile beş arasında değişmektedir. Eğitimler 1000 döngü boyunca devam ettirilmiştir. Optimizasyon yöntemi olarak *Adam* seçilmiş, öğrenme oranı 10^{-4} olarak seçilmiş ve kayıp fonksiyonunda ilerleme olmazsa 3 döngü sonra öğrenme oranı %10 azaltılmış ve nihai öğrenme oranı 10^{-5} olarak belirlenmiştir. Çalışmanın akış şeması Şekil 4.12’de gösterildiği gibidir.




Şekil 4.11. a) Yükseklik Kayması, b) Yatay Çevirme, c) Döndürme, d) Kesme, e) Genişlik Kaydırma, f) Yakınlaştırma




Şekil 4.12. Abdomen segmentasyon çalışmasının akış şeması

Daha sonra çalışma performansını iyileştirmek amacıyla görüntülere ADD, KSUHE ve füzyon (maksimum füzyon-ortalama füzyon) ön işleme yöntemleri uygulanmıştır. Veri setindeki görüntülere uygulanan bu işlemler sonrasında elde edilen

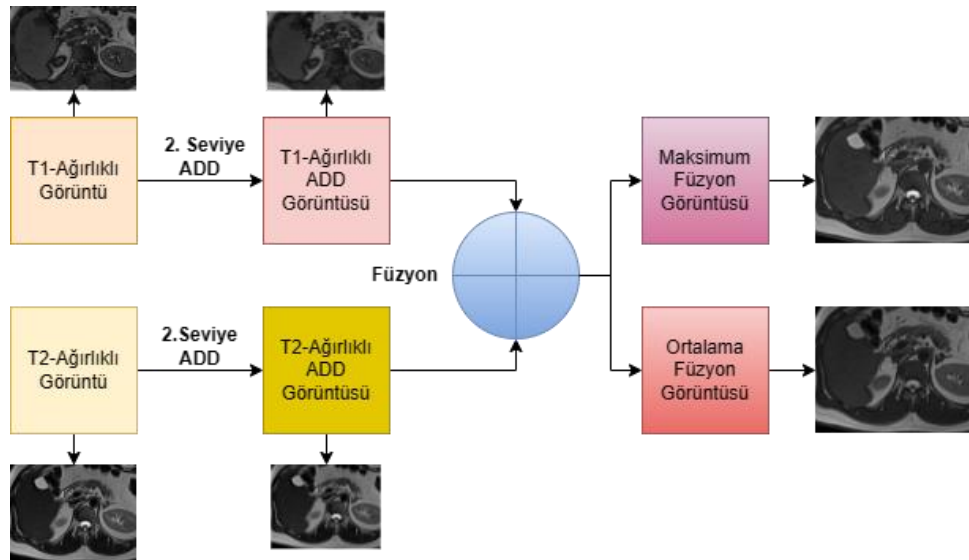
görüntülere ait örnekler ADD, KSUHE, füzyon için sırasıyla Şekil 4.13, Şekil 4.14 ve Şekil 4.15'te paylaşılmıştır. Ön işleme yöntemleriyle elde edilen veri setleri için bir önceki paragrafta anlatılan eğitim işlemleri tekrarlanmıştır.



Şekil 4.13. (a) T1 görüntü ve karşılık gelen 2-Seviye ADD görüntüsü,
(b) T2 görüntü ve karşılık gelen 2-Seviye ADD görüntüsü



Şekil 4.14. a) T-1 Görüntüsü, b) T-1 KSUHE Görüntüsü, c) T-2 Görüntüsü, d) T-2 KSUHE Görüntüsü



Şekil 4.15. T1-T2 Ağırlık Görüntülerden Maksimum Füzyon ve Ortalama Füzyon

Eğitim işlemleri segmentasyon sonucunu iyileştirmek için tez çalışması kapsamında geliştirilen modifiye edilmiş U-Net modeli için devam ettirilmiştir. Bu model için de tüm veri setleri için aynı eğitimler yapılmıştır. Modellerde kullanılan hiper parametre değerleri Çizelge 4.20'de verilmiştir.

Çizelge 4.20. Abdomen segmentasyon çalışmasında kullanılan hiper parametreler

Kayıp Fonksiyonu: <i>Dice Kayıp Fonk.</i>
Öğrenme Oranı: 10^{-4} : 10^{-5}
Optimizasyon: <i>Adam</i>
Aktivasyon Fonksiyonu: <i>ReLU, PReLU</i>
Döngü: <i>1000</i>

Çalışmanın son bölümünde ise yapılan eğitimler sonucunda optimum sonucu veren k-kat ÇD ve yığın boyutu değerlerine göre veri setleri en iyi (state-of-the-art) modeller ve farklı kayıp fonksiyonları kullanılarak eğitilmiştir. Elde edilen sonuçlar, çalışmanın sonuçları ile karşılaştırılmıştır.

4.4.2. Abdomen veri setiyle yapılan segmentasyon çalışmasının sonuçları

4.4.2.1. T1 ağırlıklı görüntüler için nicel sonuçlar

Çalışmanın eğitim bölümünde öncelikle U-Net modeli T1 ağırlıklı abdomen görüntülerle eğitilmiştir. Eğitim sonucunda k-kat ÇD ile test için ayrılan görüntüler her bir kat için ayrı ayrı değerlendirilmiş ve bu değerlendirme sonuçlarının ortalaması alınmıştır. Çizelge 4.21, ham haliyle, ADD ve KSUHE uygulanmış T1 ağırlıklı görüntülerle eğitim sonunda elde edilen test sonuçlarını göstermektedir.

Çizelge 4.21. T1 ağırlıklı abdomen görüntülerle U-Net modeli üzerinde yapılan eğitim sonrası elde edilen ortalama test sonuçları

Yığın Boyutu	Metrik	İlgi Alanı			İlgi Alanına ADD Uygulanmış			İlgi Alanına KSUHE Uygulanmış		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.456	0.583	0.504	0.517	0.600	0.524	0.398	0.500	0.431
	JO	0.362	0.476	0.403	0.419	0.516	0.432	0.311	0.397	0.335
	DUY	0.379	0.545	0.415	0.461	0.516	0.385	0.306	0.470	0.300
	ÖZG	0.379	0.998	0.997	0.997	0.997	0.997	0.998	0.998	0.998
2	DK	0.422	0.514	0.497	0.451	0.608	0.543	0.391	0.482	0.441
	JO	0.329	0.412	0.399	0.361	0.509	0.448	0.306	0.388	0.346
	DUY	0.300	0.487	0.381	0.397	0.529	0.420	0.280	0.440	0.309
	ÖZG	0.998	0.998	0.998	0.996	0.997	0.996	0.998	0.997	0.998
3	DK	0.393	0.537	0.472	0.442	0.611	0.472	0.354	0.520	0.446
	JO	0.302	0.446	0.380	0.355	0.507	0.383	0.268	0.414	0.343
	DUY	0.288	0.502	0.332	0.460	0.531	0.336	0.278	0.468	0.311
	ÖZG	0.990	0.998	0.998	0.991	0.998	0.998	0.981	0.998	0.997
4	DK	0.397	0.513	0.470	0.475	0.566	0.508	0.352	0.469	0.428
	JO	0.309	0.421	0.372	0.373	0.472	0.416	0.267	0.376	0.331
	DUY	0.318	0.478	0.352	0.567	0.504	0.367	0.319	0.443	0.308
	ÖZG	0.965	0.997	0.994	0.963	0.998	0.998	0.978	0.998	0.992
5	DK	0.383	0.474	0.425	0.455	0.565	0.481	0.358	0.432	0.428
	JO	0.289	0.378	0.333	0.364	0.464	0.387	0.268	0.331	0.330
	DUY	0.281	0.438	0.341	0.508	0.518	0.445	0.306	0.483	0.382
	ÖZG	0.997	0.998	0.949	0.983	0.994	0.996	0.971	0.974	0.961

*k = Çapraz doğrulama kat sayısı

Çizelge 4.21’de her bir veri seti için ayrı ayrı görüleceği üzere, ham veri seti için tüm k-kat değerlerinde en iyi sonuçlar yığın boyutu 1 seçildiğinde elde edilmiştir. Yapılan çalışmalar neticesinde en iyi sonuçlar 3-kat ÇD ile elde edilmiş olup DK, JO, DUY ve ÖZG değerleri sırasıyla 0.583, 0.476, 0.545 ve 0.998 olarak hesaplanmıştır. ADD uygulanan veri seti ile yapılan çalışmalarda her k-kat değeri için farklı yığın boyutlarında en iyi sonuçların elde edildiği görülmektedir. Bu veri seti için en iyi test sonuçları yığın boyutu 3 için 3-kat ÇD’dir. DK, JO, DUY ve ÖZG değerleri sırasıyla 0.611, 0.507, 0.531,

0.998 olarak elde edilmiştir. Son olarak KSUHE uygulanmış veri seti ile yapılan çalışmanın sonuçları incelendiğinde farklı ÇD değerlerinde en iyi sonuçların farklı yığın boyutlarında olduğu görülmektedir. Bu veri kümesi için en iyi sonuç, yığın boyutu 3 için 3-kat ÇD'dır; DK, JO, DUY ve ÖZG değerleri sırasıyla 0.520, 0.414, 0.468, 0.998 olarak elde edilmiştir. Tüm veri setleri için yapılan çalışmalar incelendiğinde en iyi sonuçların ADD veri seti ile yapılan çalışmada elde edildiği açıkça görülmektedir.

Çalışmanın ikinci bölümünde T1 ağırlıklı veri seti ve oluşturulan veri setleri bu kez PReLU ile modifiye edilmiş U-Net modeli ile eğitilmiştir. İlk bölümde olduğu gibi her bir veri seti ile farklı k-kat ve yığın değerleri için ayrı ayrı eğitimler gerçekleştirilmiş, test görüntüleri ile değerlendirmeler yapılmıştır. Çizelge 4.22, T1 ağırlıklı veri setinin modifiye edilmiş U-Net modeli ile yapılan çalışmalar sonucunda elde edilen nicel sonuçlarını göstermektedir.

Çizelge 4.22. T1 ağırlıklı abdomen görüntülerle modifiye edilmiş U-Net modeli üzerinde yapılan eğitim sonrası elde edilen ortalama test sonuçları

Yığın Boyutu	Metrik	İlgi Alanı			İlgi Alanına ADD Uygulanmış			İlgi Alanına KSUHE Uygulanmış		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.471	0.554	0.491	0.485	0.631	0.523	0.426	0.497	0.463
	JO	0.373	0.454	0.398	0.393	0.533	0.430	0.332	0.393	0.364
	DUY	0.349	0.530	0.364	0.474	0.579	0.375	0.312	0.465	0.327
	ÖZG	0.998	0.998	0.995	0.996	0.998	0.998	0.998	0.997	0.998
2	DK	0.455	0.573	0.491	0.461	0.631	0.524	0.416	0.513	0.531
	JO	0.356	0.466	0.395	0.375	0.525	0.433	0.321	0.409	0.434
	DUY	0.353	0.538	0.331	0.453	0.574	0.364	0.327	0.455	0.366
	ÖZG	0.997	0.998	0.998	0.996	0.997	0.998	0.998	0.998	0.997
3	DK	0.429	0.533	0.468	0.482	0.612	0.537	0.394	0.495	0.438
	JO	0.337	0.439	0.376	0.382	0.508	0.437	0.302	0.398	0.340
	DUY	0.339	0.512	0.335	0.486	0.552	0.357	0.282	0.458	0.336
	ÖZG	0.998	0.998	0.998	0.992	0.998	0.998	0.997	0.998	0.996
4	DK	0.408	0.476	0.463	0.452	0.599	0.502	0.371	0.507	0.443
	JO	0.317	0.385	0.369	0.364	0.492	0.411	0.282	0.408	0.347
	DUY	0.433	0.451	0.317	0.435	0.536	0.417	0.326	0.461	0.306
	ÖZG	0.988	0.997	0.996	0.995	0.997	0.997	0.947	0.998	0.998
5	DK	0.369	0.488	0.443	0.449	0.597	0.503	0.344	0.470	0.414
	JO	0.281	0.393	0.351	0.356	0.492	0.408	0.259	0.368	0.321
	DUY	0.482	0.465	0.332	0.469	0.536	0.354	0.386	0.475	0.348
	ÖZG	0.913	0.993	0.968	0.982	0.995	0.998	0.941	0.966	0.959

*k = Çapraz doğrulama kat sayısı

Çizelge 4.22'de görüldüğü gibi her bir veri seti için değerlendirme sonuçları ayrı ayrı paylaşılmıştır. Burada, ham veri seti için yapılan çalışmalarda en iyi sonuçlar 2 kat ve 4 kat ÇD için yığın boyutu 1, 3 kat ÇD için ise yığın boyutu 2 için elde edilmiştir. Veri setinin bütününe bakıldığında, en iyi sonuçlar 3 kat ÇD için yığın boyutu 2 ile elde edilmiştir. Bu parametrelerle yapılan değerlendirme sonucunda DK, JO, DUY ve ÖZG

skorları sırasıyla 0.573, 0.466, 0.538 ve 0.998 olarak hesaplanmıştır. Öte yandan, ADD uygulanmış veri seti ile yapılan çalışmalarda, en iyi skorlar 2 kat ve 3 kat ÇD için yığın boyutu 1, 4 kat ÇD için yığın boyutu 3 için alınmıştır. Yine bu veri seti için yapılan çalışmaların tümüne bakıldığında en iyi sonuçların 3 kat ÇD, yığın boyutu 1 ile elde edildiği görülmektedir. Bu parametrelerde elde edilen DK, JO, DUY ve ÖZG skorları sırasıyla 0.631, 0.533, 0.579 ve 0.998'dir. Son olarak, KSUHE uygulanmış veri seti ile yapılan çalışma sonucunda en iyi sonuçlar 2 kat ÇD için yığın boyutu 1'de ve 3 kat ve 4 kat ÇD için yığın boyutu 2 için elde edilmiştir. Bu veri setinde en iyi sonuçların 4 kat ÇD, yığın boyutu 2 için elde edildiği açıkça görülmektedir. Bu parametreler için DK, JO, DUY ve ÖZG skorları sırasıyla 0.531, 0.434, 0.366 ve 0.997'dir. Tüm veri setleri için yapılan çalışmalar incelendiğinde en iyi sonuçların ADD veri seti ile yapılan çalışmada elde edildiği açıkça görülmektedir.

Bu bölümde, T1 ağırlıklı veri setlerinin U-Net ve modifiye edilmiş U-Net modelleri ile yapılan eğitim sonucunda test görüntüleri ile nicel değerlendirme sonuçları paylaşılmıştır. Çalışma sonucunda her iki model için ADD veri seti ile yapılan değerlendirmeler en iyi sonuçları vermiştir. Bu, görüntü iyileştirme kısmında hedeflenen çalışma performansının artmasını sağlamıştır. Öte yandan, KSUHE uygulanan görüntüler ile elde edilen sonuçlar ham veri setinden daha başarısızdır. Buradan KSUHE'nin T1 ağırlıklı görüntüler açısından başarısız olduğu görülmektedir. Yapılan çalışmalar sonucunda en iyi sonuçlar ADD veri seti ile modifiye edilmiş U-Net modelinde 3-kat ÇD ve yığın boyutu 1 için; DK, JO, DUY ve ÖZG skorları sırasıyla 0.631, 0.533, 0.579 ve 0.998 olarak elde edilmiştir.

4.4.2.2. T2 ağırlıklı görüntüler için nicel sonuçlar

Bu bölümde, modellerin eğitim işlemleri T2 ağırlıklı görüntüler kullanılarak gerçekleştirilmiştir. Kullanılan modeller, k-kat ÇD ve yığın boyutu değerleri T1 ağırlıklı görüntülerle yapılan çalışmadakilerle aynıdır. İlk olarak T2 ağırlıklı görüntülerle U-Net modelinin eğitimi gerçekleştirilmiştir. Çalışma sonucunda her bir veri seti için elde edilen test değerlendirme sonuçları Çizelge 4.23'teki gibidir.

Çizelge 4.23. T2 ağırlıklı abdomen görüntülerle U-Net modeli üzerinde yapılan eğitim sonrası elde edilen ortalama test sonuçları

Yığın Boyutu	Metrik	İlgi Alanı			İlgi Alanına ADD Uygulanmış			İlgi Alanına KSUHE Uygulanmış		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.412	0.482	0.470	0.318	0.417	0.391	0.425	0.398	0.475
	JO	0.320	0.392	0.375	0.245	0.332	0.310	0.331	0.306	0.373
	DUY	0.321	0.383	0.307	0.188	0.280	0.276	0.349	0.248	0.276
	ÖZG	0.997	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.998
2	DK	0.378	0.450	0.454	0.326	0.393	0.354	0.362	0.436	0.468
	JO	0.292	0.359	0.359	0.252	0.302	0.280	0.280	0.342	0.374
	DUY	0.344	0.356	0.238	0.195	0.291	0.212	0.330	0.273	0.265
	ÖZG	0.997	0.999	0.998	0.999	0.998	0.999	0.999	0.999	0.999
3	DK	0.300	0.443	0.440	0.284	0.384	0.367	0.329	0.340	0.427
	JO	0.230	0.355	0.347	0.217	0.296	0.293	0.258	0.262	0.338
	DUY	0.413	0.433	0.378	0.218	0.267	0.232	0.286	0.214	0.213
	ÖZG	0.872	0.998	0.995	0.996	0.999	0.999	0.995	0.999	0.999
4	DK	0.374	0.435	0.400	0.314	0.377	0.371	0.337	0.431	0.415
	JO	0.284	0.343	0.317	0.236	0.296	0.291	0.260	0.334	0.328
	DUY	0.353	0.388	0.282	0.167	0.254	0.264	0.181	0.274	0.293
	ÖZG	0.998	0.998	0.998	0.998	0.999	0.998	0.999	0.999	0.998
5	DK	0.300	0.373	0.389	0.257	0.334	0.341	0.305	0.328	0.409
	JO	0.224	0.291	0.310	0.187	0.252	0.262	0.232	0.250	0.320
	DUY	0.338	0.534	0.331	0.275	0.235	0.332	0.259	0.294	0.246
	ÖZG	0.978	0.895	0.998	0.961	0.998	0.986	0.979	0.981	0.999

*k = Çapraz doğrulama kat sayısı

Çizelge 4.23'te görüldüğü gibi, ham veri seti ile yapılan çalışma sonucunda her k-kat ÇD değeri için yığın boyutu 1 seçildiğinde en iyi sonuçlar elde edilmiştir. Bu veri setindeki tüm k-kat çalışmalar arasında en iyi sonuç, yığın boyutu 1 için 3 kat ÇD'dir. Bu parametrelerle yapılan değerlendirme sonucunda DK, JO, DUY ve ÖZG skorları sırasıyla 0.482, 0.392, 0.383 ve 0.999 olarak elde edilmiştir. ADD veri setinde; 2 kat ÇD için yığın boyutu 2 ve diğerleri için yığın boyutu 1 en iyi sonuçları vermiştir. Bu veri seti üzerinde yapılan çalışmalar sonucunda en iyi sonuçlar yığın boyutu 1 için 3 kat ÇD'dir. Bu parametreler için değerlendirme sonuçları DK, JO, DUY ve ÖZG skorları sırasıyla 0.417, 0.332, 0.280 ve 0.999 olarak elde edilmiştir. KSUHE veri seti ile yapılan çalışma sonucunda 2 kat ve 4 kat ÇD için yığın boyutu 1, 3 kat ÇD için yığın boyutu 2 en iyi sonuçları vermiştir. Bu veri seti üzerinde yapılan çalışmalar sonucunda en iyi sonuçlar yığın boyutu 1 için 4 kat ÇD'dir. Bu parametreler için değerlendirme sonuçları şöyledir: DK, JO, DUY ve ÖZG skorları sırasıyla 0.475, 0.373, 0.276 ve 0.998 olarak elde

edilmiştir. Çizelge 4.23'te açıkça görülebileceği gibi, ham veri seti ile yapılan çalışmalar en iyi sonuçları vermiştir.

Bölümün ikinci kısmında, T2 ağırlıklı veri setleriyle bu kez modifiye edilmiş U-Net modeli eğitilmiştir. Bir önceki bölümde olduğu gibi her bir veri seti, k-kat ÇD ve yığın değerleri için ayrı ayrı eğitim sonucunda test görüntüleri ile değerlendirmeler yapılmıştır. Çizelge 4.24'te, bu değerlendirmelerin nicel sonuçları gösterilmektedir.

Çizelge 4.24. T2 ağırlıklı abdomen görüntülerle modifiye edilmiş U-Net modeli üzerinde yapılan eğitim sonrası elde edilen ortalama test sonuçları

Yığın Boyutu	Metrik	İlgi Alanı			İlgi Alanına ADD Uygulanmış			İlgi Alanına KSUHE Uygulanmış		
		k=2	k=3	k=4	k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.430	0.503	0.470	0.376	0.434	0.399	0.399	0.395	0.486
	JO	0.333	0.405	0.375	0.291	0.339	0.317	0.311	0.308	0.391
	DUY	0.360	0.366	0.280	0.291	0.293	0.268	0.276	0.243	0.257
	ÖZG	0.997	0.998	0.998	0.998	0.999	0.999	0.999	0.999	0.999
2	DK	0.412	0.476	0.462	0.338	0.378	0.370	0.376	0.407	0.433
	JO	0.319	0.378	0.370	0.263	0.300	0.297	0.290	0.315	0.342
	DUY	0.343	0.405	0.344	0.236	0.264	0.220	0.285	0.258	0.258
	ÖZG	0.998	0.999	0.998	0.998	0.999	0.999	0.998	0.999	0.998
3	DK	0.364	0.447	0.417	0.355	0.376	0.372	0.343	0.397	0.449
	JO	0.281	0.356	0.332	0.276	0.290	0.296	0.265	0.312	0.353
	DUY	0.384	0.372	0.328	0.193	0.248	0.233	0.260	0.227	0.284
	ÖZG	0.993	0.999	0.998	0.998	0.998	0.999	0.999	0.999	0.999
4	DK	0.383	0.447	0.430	0.305	0.371	0.382	0.371	0.427	0.405
	JO	0.297	0.351	0.345	0.229	0.290	0.300	0.282	0.326	0.325
	DUY	0.356	0.365	0.357	0.170	0.252	0.273	0.326	0.276	0.217
	ÖZG	0.999	0.999	0.998	0.999	0.999	0.998	0.947	0.999	0.999
5	DK	0.293	0.394	0.436	0.307	0.371	0.365	0.329	0.363	0.426
	JO	0.218	0.301	0.349	0.233	0.288	0.288	0.253	0.278	0.331
	DUY	0.488	0.333	0.372	0.174	0.262	0.232	0.193	0.234	0.247
	ÖZG	0.857	0.980	0.998	0.992	0.999	0.999	0.999	0.998	0.998

*k = Çapraz doğrulama kat sayısı

Çizelge 4.24'te görüldüğü gibi, ham veri seti ile yapılan çalışma sonucunda her bir k-kat ÇD değeri için yığın boyutu 1 seçildiğinde en iyi sonuçlar elde edilmiştir. Bu veri setindeki tüm k-kat ÇD çalışmaları arasında en iyi sonuçlar, yığın boyutu 1 için 3 kat ÇD'dir. Bu parametreler için değerlendirme sonuçları şöyledir: DK, JO, DUY ve ÖZG skorları sırasıyla 0.503, 0.405, 0.366 ve 0.998. ADD veri seti için en iyi sonuçlar, yine tüm k-kat ÇD değerleri için yığın boyutu 1 ile elde edilmiştir. Bu veri seti üzerinde yapılan çalışmalar sonucunda elde edilen en iyi sonuçlar, yığın boyutu 1 için 3 kat ÇD'da

DK, JO, DUY ve ÖZG skorları sırasıyla 0.434, 0.399, 0.293 ve 0.999 olarak elde edilmiştir. KSUHE veri seti ile yapılan çalışma sonucunda, 2 kat ve 4 kat ÇD için yığın boyutu 1, 3 kat ÇD için yığın boyutu 4 en iyi sonuçları vermiştir. Bu veri seti üzerinde yapılan çalışmalar sonucunda en iyi sonuç yığın boyutu 1 için 4 kat ÇD'dir. Bu parametrelerle yapılan değerlendirme sonucunda DK, JO, DUY ve ÖZG skorları sırasıyla 0.486, 0.391, 0.257 ve 0.999 olarak elde edilmiştir. Çizelge 4.24'ten açıkça görülebileceği gibi, ham veri seti ile yapılan çalışmalar en iyi sonuçları vermiştir.

Bu bölümde, T2 ağırlıklı veri setleriyle U-Net ve modifiye edilmiş U-Net modellerinin eğitimleri sonucunda test görüntüleri ile nicel değerlendirme sonuçları paylaşılmıştır. Çalışma sonucunda her iki model için de ham veri seti ile yapılan değerlendirmeler en iyi sonuçları vermiştir. Görüntü iyileştirme için kullanılan veri setleri incelendiğinde, KSUHE uygulanan veri setleri ile yapılan çalışmanın sonuçları, ADD uygulanan veri seti ile yapılan çalışmaların sonuçlarından daha başarılıdır. Ancak bu iki ön işlemin çalışma boyunca uygulanmasındaki amaç ham veri seti ile elde edilen performansı iyileştirmek olduğundan, T2 ağırlıklı görüntüler için bu işlemlerin genellikle başarısız olduğu söylenebilir. T2 ağırlıklı görüntüler üzerinde yapılan çalışmalarda en iyi sonuçlar ham veri seti kullanılarak modifiye edilmiş U-Net modelinde 3-kat ÇD ve yığın boyutu 1 seçildiğinde DK, JO, DUY ve ÖZG sırasıyla 0.503, 0.405, 0.366 ve 0.998 olarak elde edilmiştir.

4.4.2.3. Füzyon görüntüleri için nicel sonuçlar

Bu bölümde, T1 ve T2 ağırlıklı görüntüler üzerinde maksimum ve ortalama füzyon işlemleri uygulanması sonucunda elde edilen veri setleri ile eğitim işlemleri gerçekleştirilmiştir. Her iki veri seti için k-kat ÇD ve yığın boyutu değerleri önceki bölümlerde açıklananlarla aynıdır. Çizelge 4.25'te, U-Net modelinin füzyon görüntüleriyle eğitimi sonucunda elde edilen nicel sonuçlar gösterilmektedir.

Çizelge 4.25. Abdomen füzyon görüntülerle U-Net modeli üzerinde yapılan eğitim sonrası elde edilen ortalama test sonuçları

Yığın Boyutu	Metrik	Maksimum Füzyon			Ortalama Füzyon		
		k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.373	0.473	0.429	0.317	0.484	0.447
	JO	0.290	0.384	0.340	0.238	0.391	0.356
	DUY	0.265	0.373	0.239	0.285	0.435	0.323
	ÖZG	0.998	0.999	0.998	0.996	0.999	0.997
2	DK	0.337	0.479	0.448	0.317	0.469	0.364
	JO	0.265	0.371	0.355	0.240	0.378	0.287
	DUY	0.247	0.404	0.239	0.296	0.402	0.312
	ÖZG	0.997	0.998	0.998	0.995	0.999	0.997
3	DK	0.306	0.426	0.390	0.310	0.417	0.414
	JO	0.234	0.345	0.311	0.230	0.330	0.323
	DUY	0.373	0.344	0.221	0.346	0.314	0.335
	ÖZG	0.953	0.999	0.998	0.956	0.999	0.997
4	DK	0.285	0.430	0.424	0.297	0.450	0.368
	JO	0.212	0.348	0.335	0.228	0.357	0.290
	DUY	0.177	0.344	0.218	0.333	0.371	0.326
	ÖZG	0.995	0.998	0.998	0.995	0.999	0.997
5	DK	0.269	0.374	0.375	0.268	0.414	0.379
	JO	0.200	0.294	0.293	0.199	0.321	0.293
	DUY	0.234	0.384	0.292	0.397	0.411	0.343
	ÖZG	0.992	0.973	0.965	0.953	0.994	0.995

*k = Çapraz doğrulama kat sayısı

Çizelge 4.25'te görüldüğü gibi, maksimum füzyon uygulanan veri seti için elde edilen sonuçlarda, model en iyi performansı 2 kat ÇD için yığın boyutu 1, diğer ÇD'larda yığın boyutu 2 için göstermiştir. Bu veri seti ile çalışmanın tamamına bakıldığında, en iyi sonuçların 3 kat ÇD ve yığın boyutu 2 için elde edildiği çizelgeden açıkça görülmektedir. Bu parametrelerdeki değerlendirme sonuçları DK, JO, DUY ve ÖZG skorları sırasıyla 0.479, 0.371, 0.404 ve 0.998 olarak elde edilmiştir. Ortalama füzyon uygulanan veri seti ile yapılan çalışmalarda, en iyi sonuçlar 2 kat ÇD için yığın boyutu 2'de, diğerlerinde ise yığın boyutu 1'de elde edildiği görülmektedir. Bu veri seti ile yapılan çalışmalar karşılaştırıldığında, en iyi sonuçların 3 kat ÇD ve yığın boyutu 1 seçildiğinde elde edildiği açıkça görülmektedir. Bu parametrelerdeki değerlendirme sonuçları şu şekildedir: DK, JO, DUY ve ÖZG skorları sırasıyla 0.484, 0.391, 0.435 ve 0.999 olarak elde edilmiştir. Çizelge 4.25'te açıkça görüleceği üzere U-Net modeli ile yapılan eğitimler sonucunda en iyi performans ortalama füzyon görüntülerinde elde edilmiştir.

İkinci kısmında, füzyon görüntüleri bu kez modifiye edilmiş U-Net modelinin eğitimi için kullanılmıştır. Bir önceki bölümde olduğu gibi her bir veri seti, k-kat ve yığın değerleri için ayrı ayrı eğitim sonucunda test görüntüleri ile değerlendirmeler yapılmıştır. Çizelge 4.26'da füzyon görüntülerinde modifiye edilmiş U-Net modeli ile yapılan çalışmalar sonucunda elde edilen nicel sonuçlar gösterilmektedir.

Çizelge 4.26. Abdomen füzyon görüntülerle modifiye edilmiş U-Net modeli üzerinde yapılan eğitim sonrası elde edilen ortalama test sonuçları

Yığın Boyutu	Metrik	Maksimum Füzyon			Ortalama Füzyon		
		k=2	k=3	k=4	k=2	k=3	k=4
1	DK	0.362	0.426	0.444	0.294	0.348	0.404
	JO	0.268	0.337	0.341	0.209	0.261	0.305
	DUY	0.276	0.363	0.251	0.234	0.206	0.354
	ÖZG	0.997	0.999	0.998	0.996	0.999	0.997
2	DK	0.342	0.367	0.410	0.285	0.443	0.406
	JO	0.256	0.272	0.314	0.206	0.339	0.312
	DUY	0.264	0.285	0.234	0.306	0.345	0.329
	ÖZG	0.997	0.998	0.999	0.997	0.999	0.997
3	DK	0.229	0.403	0.390	0.277	0.422	0.390
	JO	0.163	0.317	0.299	0.199	0.325	0.298
	DUY	0.201	0.351	0.224	0.347	0.338	0.329
	ÖZG	0.961	0.999	0.997	0.981	0.999	0.998
4	DK	0.264	0.392	0.380	0.274	0.427	0.373
	JO	0.198	0.307	0.292	0.200	0.335	0.279
	DUY	0.198	0.319	0.210	0.326	0.379	0.300
	ÖZG	0.997	0.999	0.999	0.996	0.999	0.998
5	DK	0.292	0.324	0.363	0.281	0.402	0.344
	JO	0.208	0.247	0.282	0.199	0.308	0.256
	DUY	0.307	0.255	0.231	0.352	0.454	0.333
	ÖZG	0.961	0.995	0.978	0.986	0.986	0.998

*k = Çapraz doğrulama kat sayısı

Çizelge 4.26'da görüldüğü üzere, maksimum füzyon uygulanan veri seti için elde edilen sonuçlarda, model en iyi performansı tüm ÇD değerleri için yığın boyutu 1 seçildiğinde elde etmiştir. Bu veri seti ile yapılan eğitimlerin tamamına bakıldığında, en iyi sonuçların 4 kat ÇD, yığın boyutu 1 için elde edildiği çizelgeden net bir şekilde görülmektedir. Bu parametrelerdeki değerlendirme sonuçları şöyledir: DK, JO, DUY ve ÖZG sırasıyla 0.444, 0.341, 0.251 ve 0.998 olarak elde edilmiştir. Ortalama füzyon uygulanan veri seti ile yapılan çalışmalarda, en iyi sonuçların 2 kat ÇD için yığın boyutu 1'de, diğerleri için yığın boyutu 2'de elde edildiği görülmektedir. Bu veri seti ile yapılan

çalışmalar karşılaştırıldığında, en iyi sonuçların 3 kat ÇD ve yığın boyutu 2 ile elde edildiği açıkça görülmektedir. Bu parametrelerdeki değerlendirme sonuçları şu şekildedir: DK, JO, DUY ve ÖZG skorları sırasıyla 0.443, 0.339, 0.345 ve 0.999 olarak elde edilmiştir. Çizelge 4.26'dan açıkça görüleceği üzere modifiye edilmiş U-Net modeli ile yapılan eğitim sonucunda en iyi performans maksimum füzyon görüntülerinde elde edilmiştir.

Bu bölümde, füzyon veri setlerinin U-Net ve modifiye edilmiş U-Net modellerinin eğitimleri sonucunda test görüntüleri ile nicel değerlendirme sonuçları paylaşılmaktadır. Çalışma sonucunda U-Net modeli için ortalama füzyon görüntülerinde, modifiye edilmiş U-Net modeli için maksimum füzyon görüntülerinde elde edilen sonuçlar daha başarılıdır. Bu bölümde yapılan çalışmaların bütününe bakıldığında en iyi sonuçlar U-Net ile ortalama füzyon görüntülerinde elde edilmiştir.

4.4.2.4. Abdomen segmentasyonunda nicel sonuçların değerlendirilmesi

Bu bölüm, önceki bölümlerde yapılan çalışmaların nicel sonuçlarının karşılaştırmasını ve yorumlanmasını içermektedir. Öncelikle her bir veri seti için elde edilen en başarılı sonuçlar karşılaştırılmıştır. Bu karşılaştırma yapılırken diğer bölümlerdeki metriklere ek olarak karşılaştırma için HM metriği de dikkate alınmıştır. Çizelge 4.27'de veri setlerinde elde edilen en iyi sonuçlar sunulmaktadır.

Çizelge 4.27. Çalışmadaki en iyi nicel sonuçlar

Veri Seti	Model	Parametre	Metrik				
			DK	JO	DUY	ÖZG	HM (mm)
T1-(İA-ADD)	Modifiye Edilmiş U-Net	k:3-B:1	0.631	0.533	0.579	0.998	2.950
T2-(İA)	Modifiye Edilmiş U-Net	k:3-B:1	0.503	0.405	0.366	0.998	2.854
Füzyon (Ortalama Füzyon)	U-Net	k:3-B:1	0.484	0.391	0.435	0.999	2.716

*k = k kat değeri, B = Yığın boyutu

Çizelge 4.27'de her bir veri seti için elde edilen en iyi sonuçlar ayrı ayrı incelendiğinde, T1 ağırlıklı görüntülerde, ADD uygulanmış veri seti ile modifiye edilmiş U-Net modeli, 3-kat ÇD ve yığın boyutu 1 iken en iyi sonuçlar DK, JO, DUY, ÖZG ve

HM skorları için sırasıyla 0.631, 0.533, 0.579, 0.998 ve 2.950 olarak elde edilmiştir. T2 ağırlıklı görüntüler arasında ham veri seti ile yapılan çalışmada, modifiye edilmiş U-Net modeli ile 3-kat ÇD ve yığın boyutu 1 iken, en iyi sonuçlar DK, JO, DUY, ÖZG ve HM skorları sırasıyla 0.503, 0.405, 0.366, 0.998 ve 2.854 olarak elde edilmiştir. Görüntü füzyonu uygulanan veri setleri ile yapılan eğitimler sonucunda en iyi sonuçlar ortalama füzyon veri setinde U-Net modeli ile 3-kat ÇD ve yığın boyutu 1 iken; DK, JO, DUY, ÖZG ve HM skorları sırasıyla 0.484, 0.391, 0.435, 0.999 ve 2.716 olarak elde edilmiştir.

Kullanılan veri setlerinden T1 ağırlıklı görüntülerle eğitim sonucunda elde edilen sonuçların diğer sonuçlardan daha iyi olduğu Çizelge 4.27’de açıkça görülmektedir. Ayrıca tüm veri setlerinde ortak olan en iyi sonuçlar 3 kat ÇD ve yığın boyutu 1 ile elde edilmiştir. Görüntü füzyonu veri setleri ile elde edilen sonuçlar, T1 ve T2 ağırlıklı görüntüler ile yapılan çalışmaların sonuçları ile karşılaştırıldığında abdomen görüntüler için füzyon metodunun başarısız olduğu görülebilir.

Çalışmanın sonraki aşamasında en iyi sonuçların ulaşıldığı veri seti (T1-(İA-ADD)), ÇD (3) ve yığın boyutu (1) değerleriyle farklı kayıp fonksiyonları ve en iyi modeller kullanılarak eğitimler yapılmış, bulunan nitel ve nicel sonuçlar karşılaştırılmıştır. Karşılaştırma için kullanılan en iyi modeller: DeepLabV3+, SegNet ve U-Net++ modelleridir. Bu kısımda U-Net modeli içerisinde kullanılan farklı kayıp fonksiyonları ise İkili Çapraz Entropi (İÇE (Binary Cross Entropy -BCE)), Tversky kayıp fonksiyonu ve Focal-Tversky kayıp fonksiyonudur. Yapılan çalışmalar sonucunda elde edilen ortalama test sonuçları Çizelge 4.28’de verilmiştir.

Çizelge 4.28. Farklı kayıp fonksiyonları ve en son modellerle yapılan çalışmaların ortalama test sonuçları

Model	Metrik						Eğitilen Parametre Sayısı (Milyon)	Eğitim Süresi
	DK	JO	DUY	ÖZG	HM (mm)			
DeepLabV3+ (Chen ve ark., 2018)	0.557	0.457	0.477	0.997	2.427	17.83	15:16:21	
SegNet (Badrinarayanan ve ark., 2017)	0.576	0.459	0.522	0.995	2.013	2.941	3:13:06	
U-Net++ (Zhou ve ark., 2018)	0.566	0.474	0.518	0.997	3.060	8.193	13:58:29	
(Barstuğan ve ark., 2018)	0.631	0.511	0.600	0.998	-	-	-	
*Modifiye Edilmiş U-Net (Dice Kaybı)	0.631	0.533	0.579	0.998	2.950	36.535	12:45:01	
*Modifiye Edilmiş U-Net (İÇE Kaybı)	0.416	0.327	0.320	0.995	3.167	36.535	12:25:05	
*Modifiye Edilmiş U-Net (Tversky Kaybı)	0.500	0.402	0.382	0.995	3.030	36.535	12:16:35	
*Modifiye Edilmiş U-Net (Focal-Tversky Kaybı)	0.499	0.404	0.383	0.995	3.166	36.535	12:17:01	

*Bu Çalışma

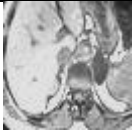


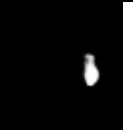


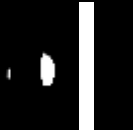



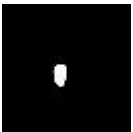







Farklı modeller ve kayıp fonksiyonları ile yapılan çalışmalar sonucunda elde edilen ortalama kantitatif test sonuçları ile (Barstuğan ve ark., 2018)’in makine öğrenimi yöntemiyle yapmış oldukları çalışmaya ait sonuçlar Çizelge 4.28’de verilmiştir. Çizelge


4.28'deki kantitatif sonuçlar metrik bazında incelendiğinde her bir metrik için en iyi sonuçlar şu şekildedir: DK için en iyi skor 0.631 ile hem bu çalışmaya hem de (Barstuğan ve ark., 2018)'a aittir. JO için en iyi skora 0.533 ile bu çalışma sahiptir. DUY için en iyi skoru 0.600 ile (Barstuğan ve ark., 2018) elde etmişlerdir. ÖZG için en iyi skor 0.998 ile hem bu çalışmada hem de (Barstuğan ve ark., 2018)'nın yaptığı çalışmada bulunmuştur. SegNet, HM için 2.013 mm ile en iyi skora sahiptir. En az parametre kullanan model SegNet olduğu için en az eğitim süresine sahip model de yine o olmuştur. Çalışmada kullanılan metriklerin çoğunda elde edilen sonuçlar, diğer modellere göre net bir avantaj sağlamıştır. Bu durum çalışmanın mevcut modellere göre üstünlüğünü ortaya koymaktadır ve çalışmanın geçerliği için oldukça önemli bir göstergedir.

4.4.2.5 Abdomen segmentasyonunda görsel sonuçların değerlendirilmesi


Bu bölümde bir önceki bölümde elde edilen nicel sonuçların yanı sıra çalışmalarda elde edilen nitel sonuçlara yer verilmiştir. Önerilen modelin, literatürde en son önerilen modellerin ve farklı kayıp fonksiyonlarına sahip modellerin test görüntüleri üzerindeki tahminleri ve bu tahmin görüntülerinin DK skorları Çizelge 4.29'da verilmiştir. Bu çizelgede görülebileceği gibi, Dice kaybına sahip değiştirilmiş U-Net modeli, her test görüntüsü için en iyi DK skorlarını elde etmiştir. Bazı test görüntülerinde karşılaştırma için verilen modifiye edilmiş U-Net'in farklı kayıp fonksiyonları ile elde edilen sonuçlar da bir sonraki en iyi sonucu vermiştir.

Çizelge 4.29. Farklı kayıp fonksiyonları ve en son modellerle yapılan çalışmaların nitel test sonuçları


Test Görüntüsü	Gerçek Maske	Tahmin	Tahmin	Tahmin	Tahmin	Tahmin	Tahmin	Tahmin
		Modifiye Edilmiş U-Net (Dice Kaybı)	Modifiye Edilmiş U-Net (İÇE Kaybı)	Modifiye Edilmiş U-Net (Tversky Kaybı)	Modifiye Edilmiş U-Net (Focal-Tversky Kaybı)	(DeepLab V3+)	(U-Net ++)	(SegNet)
								
		DK=0.945	DK=0.822	DK=0.940	DK=0.835	DK=0.831	DK=0.776	DK=0.854
								
		DK=0.974	DK=0.956	DK=0.958	DK=0.950	DK=0.851	DK=0.973	DK=0.868



Modellerin doğrulama kaybı-döngü ve öğrenme oranı- döngü grafikleri sırasıyla Şekil 4.16 ve Şekil 4.17'de verilmiştir. Grafikler, her bir modelin optimum parametrelerle (3-kat ÇD, yığın boyutu 1) eğitilmesi sonucunda elde edilmiş ve ortalama değerleri göstermektedir. Şekil 4.16'da doğrulama kaybı değerleri karşılaştırıldığında modifiye edilmiş U-Net (İÇE kaybı) modelinin diğer modellere göre daha çok yakınsadığı görülmektedir. Ancak test görüntülerine geçildiğinde hem Çizelge 4.28'de hem de Çizelge 4.29'da açıkça görüleceği üzere modifiye U-Net (Dice kaybı) modeli en iyi sonuçları göstermektedir. Şekil 4.17'deki öğrenme oranları karşılaştırıldığında, DeepLab V3+ modelinin en erken yakınsama yaptığı görülmektedir. Bunun nedeni, bu modeldeki ilerlemenin diğerlerinden daha kötü olmasıdır.



Şekil 4.16. Doğrulama kaybı-döngü grafiği



Şekil 4.17. Öğrenme oranı-döngü grafiği


Hem nicel sonuçlar hem de nitel sonuçlar göz önüne alındığında modifiye edilmiş U-Net (Dice kaybı) modeli en iyi performansı göstermiştir.

4.4.2.6 Kapsül segmentasyon ağı ile yapılan abdomen segmentasyon çalışmaları

Bu kısımda, abdomen görüntüler üzerinde gerçekleştirilen adrenal lezyon segmentasyonu çalışmalarına kapsül segmentasyon ağı kullanılarak devam edilmiştir. Çalışma kapsamında kullanılan kapsül segmentasyon ağı Şekil 4.18’de verilmiştir. Şekil 4.10’da verilen polip segmentasyonunda kullanılan modelin adrenal lezyon segmentasyonu çalışmasına uyarlanması sonucunda elde edilmiştir. Giriş görüntüsü 64×64 ($H \times W$) boyutundadır. Giriş görüntüsünün verildiği konvolüsyon katmanında farklı filtre boyutlarına (1×1 , 3×3 , 5×5 , 7×7) göre çalışmalar gerçekleştirilmiştir. Bir önceki bölümde yapılan çalışmalar neticesinde elde edilen optimum sonuçlara göre ADD veri seti, 3-kat ÇD ve yığın boyutu 1 seçilerek eğitim işlemleri gerçekleştirilmiştir. Gerçekleştirilen çalışmalar neticesinde elde edilen bulgular Çizelge 4.30’da verilmiştir.

4.4.3.1. Kapsül ağlar kullanılarak gerçekleştirilen sınıflandırma çalışması

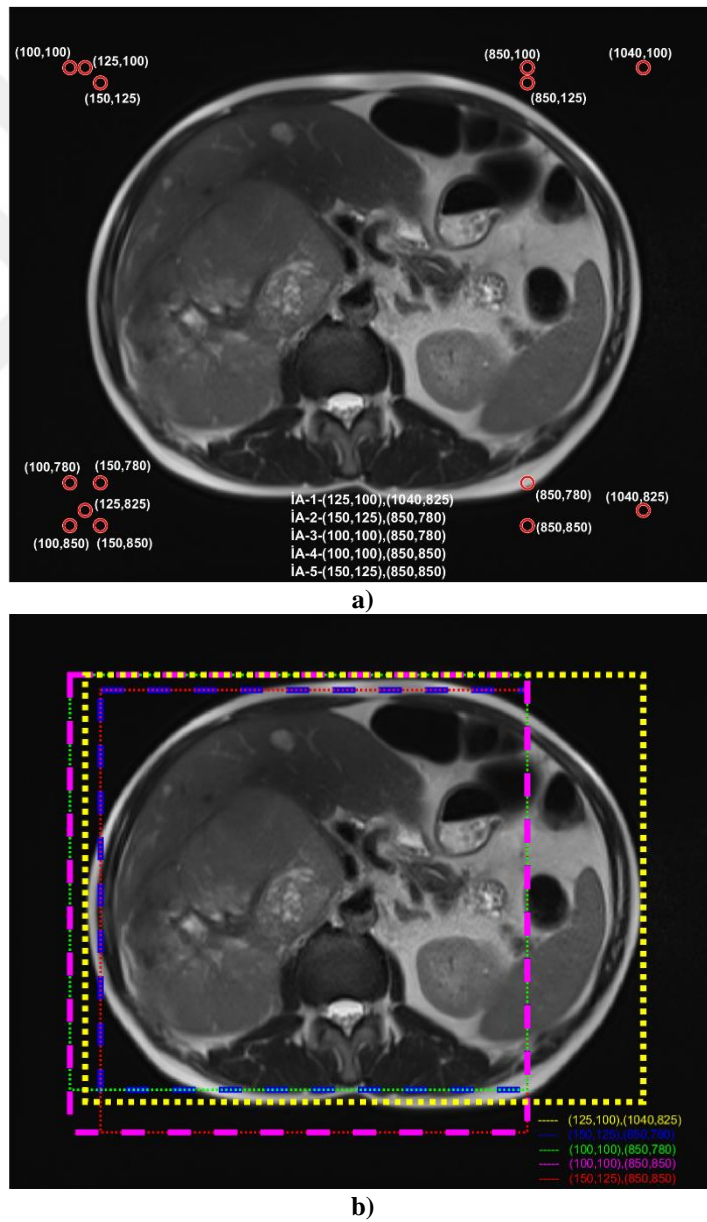
Kapsül ağlar bölüm 3.2.3'te açıklandığı üzere KSA yerine kullanılan derin öğrenme ağ yapılarından birisidir. Bu çalışma kapsamında abdomen veri setinde bulunan iyi huylu ve kötü huylu kitlelerin sınıflandırılması amacıyla “Abdomen Kapsül” olarak isimlendirilen yeni bir ağ yapısı geliştirilmiştir. Şekil 4.19’da önerilen ağ yapısı sunulmuştur. Burada giriş görüntüsü öncelikli olarak 32 adet 5x5 lik konvolüsyon filtrelerinden geçirilip sonrasında *PReLU* aktivasyon fonksiyonundan geçirilerek ilk konvolüsyon katmanı sonunda özellik haritaları oluşturulur. Sonrasında bu özellik haritaları yine 32 adet bu kez 9x9 luk konvolüsyon filtrelerinden geçirilir ve kapsüllere göre yeniden şekillendirilerek birincil kapsül katmanını oluştururlar. Birincil kapsül katmanındaki kapsüller ile abdomen kapsül katmanında bulunan sınıf sayısına göre belirlenen yüksek seviye kapsüller arasında dinamik yönlendirme algoritmasına göre kapsül çıkışı bulunarak ağırlık güncellemesi işlemi gerçekleştirilir. Bu işlemin detayları bölüm 3.2.3’te anlatılmıştır.



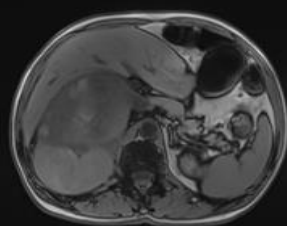
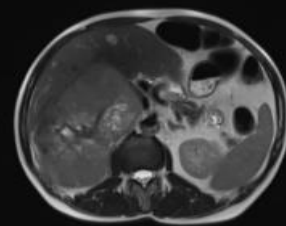
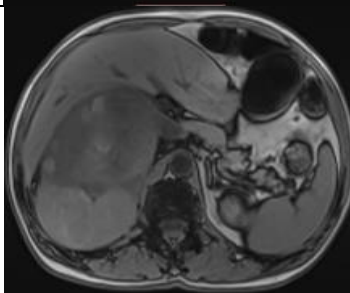
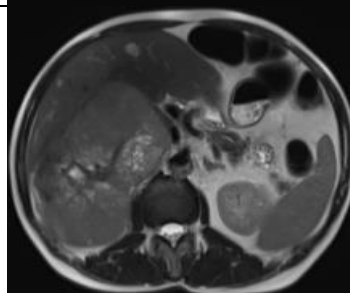
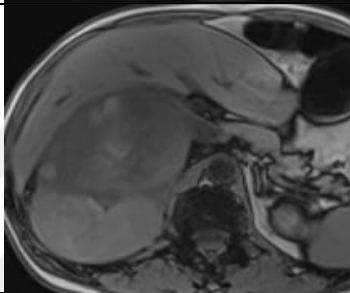
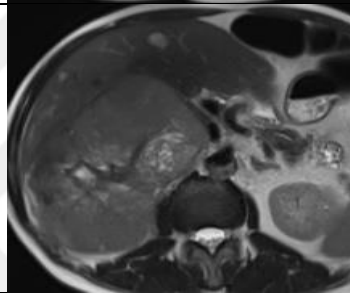
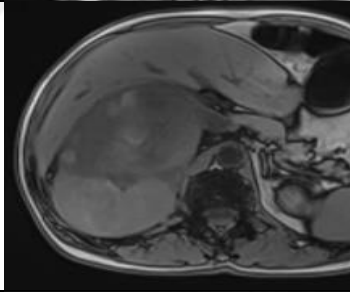
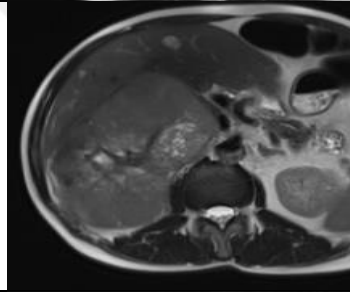
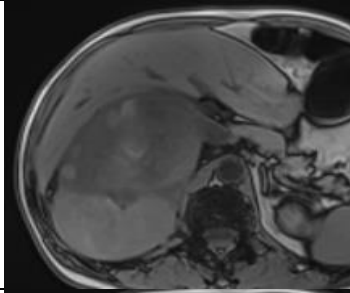
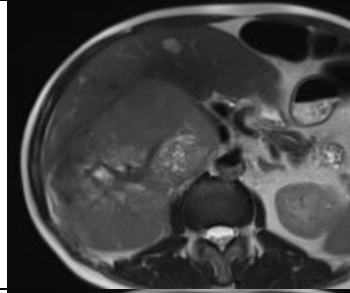
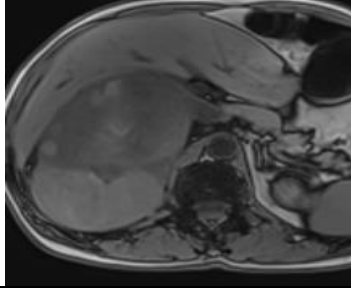
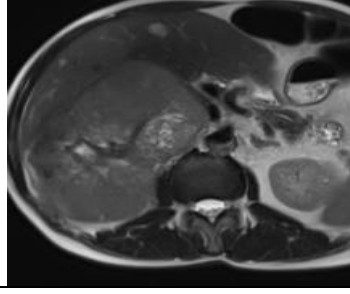
Şekil 4.19. Abdomen Kapsül ağ yapısı

MR görüntülerinde organların kontrastları birbirine yakındır. Bu yüzden teşhis aşamasında birbirine yakın organlarda hatalı değerlendirmeler yapılabilmektedir. Bunu önlemek amacıyla görüntülerden sadece çalışılacak organ veya organları çıkarma işlemi (İlgi Alanı, İA) gerçekleştirilir. Çalışılan organ her hastada farklı büyüklükte olabilir. Aynı şekilde lezyon, tümör veya kitle çalışması yapılacaksa da bunların büyüklükleri hastadan hastaya ve evreden evreye farklılık göstermektedir. Bu yüzden İA oluşturulurken kullanılan veri setindeki tüm görüntülerde ilgili her bir kitleyi kapsayacak şekilde İA çerçevesi oluşturulması elzemdir. Şekil 4.20 (a)'da bu çalışmada çıkarılan İA çerçevelerinin minimum maksimum noktaları, Şekil 4.20(b)'de ise belirlenen çerçeveler

verilmiştir. Şekil 4.20’de görüntü üzerinde gösterilen $\dot{A}((X_{\min}, Y_{\min}), (X_{\max}, Y_{\max}))$ sayıları ilgili \dot{A} çerçevesine ait eksenlerdeki minimum ve maksimum noktaları belirtmektedir. \dot{A} -1 gereksiz arka planın çıkarıldığı sadece organların olduğu bölgeyi belirtmektedir. \dot{A} -2 tüm görüntülerdeki adrenal lezyonları kapsayacak şekilde belirlenen ortak en küçük \dot{A} çerçevesidir. \dot{A} -3, \dot{A} -4 ve \dot{A} -5 ise \dot{A} -2’nin farklı yönlerde genişletilmesiyle elde edilen \dot{A} çerçeveleridir. Buradaki amaç belirlenen farklı çerçevelerin çalışmaya etkisini gözlemlemektir. Şekil 4.21’de her bir çerçeve için T1 ve T2 ağırlıklı görüntülerden çıkarılan \dot{A} örnekleri gösterilmiştir. Burada \dot{A} çerçeveleri arasındaki farklar ve görüntüde temsil edilen alan net bir şekilde görülmektedir.

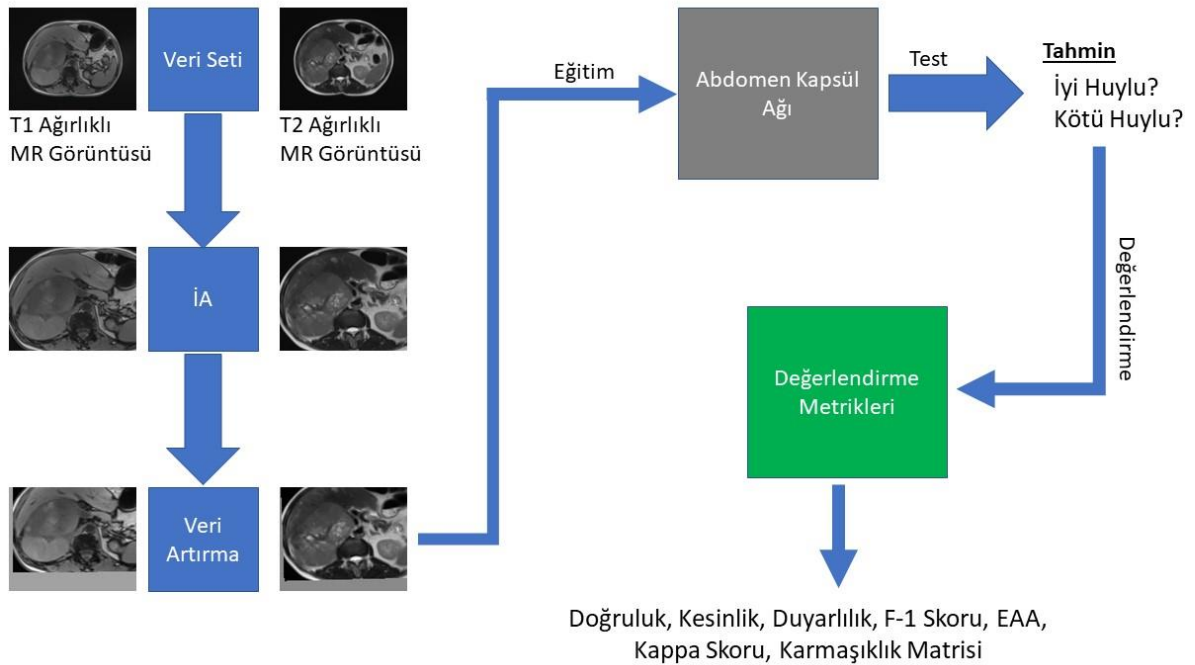


Şekil 4.20. a) Belirlenen \dot{A} çerçevelerinin maksimum ve minimum noktaları b) Belirlenen \dot{A} çerçeveleri

Görüntü Türü	T1	T2
Orijinal		
İA-1 (125,100), (1040,825)		
İA-2 (150,125), (850,780)		
İA-3 (100,100), (850,850)		
İA-4 (100,100), (850,780)		
İA-5 (150,125), (850,850)		

Şekil 4.21. T1 ve T2 ağırlıklı MR görüntülerinden çıkarılan örnek İA görüntüleri

Oluşturulan veri setleriyle Abdomen Kapsül ağı ayrı ayrı eğitilmiş ve test sonuçları değerlendirilmiştir. Çalışmanın ana şeması Şekil 4.22'de sunulmuştur. Veri setleri ağa verilmeden önce farklı veri büyütme yöntemleri (döndürme, genişlik kaydırma, yükseklik kaydırma ve çevirme) kullanılarak veri sayısı artırılmıştır. Bu şekilde 112 iyi huylu, 10 kötü huylu kitleden oluşan veri seti her sınıf için 1000 adet olmak üzere toplam 2000 adet görüntü elde edilerek veri seti genişletilmiştir. Ayrıca görüntülerin eğitim, doğrulama ve test için veri setinden manuel olarak ayrılması, ayrılan verilere göre çalışmanın performansını etkileyeceğinden, bu çalışmada 10 kat ÇD kullanılarak ortalama sonuçlar elde edilmiştir. Sınıflandırma çalışmasında Abdomen Kapsül ağının eğitimi sırasında kullanılan parametreler Çizelge 4.31'de verilmiştir. Burada yığın boyutu, yapılan denemeler sonunda en iyi performansı gösterdiği için 32 olarak seçilmiştir. Öğrenme oranı başlangıçta 10^{-3} olarak alınmış olup ve 3 döngü boyunca performansta herhangi bir gelişme olmazsa %10 azaltılarak 10^{-5} 'e kadar düşürülmüştür. Kapsül ağlarla yapılan araştırmalar göz önünde bulundurularak (Deng ve ark., 2018; Afshar ve ark., 2020; Baydilli ve Atila, 2020) eğitimler 100 döngü boyunca devam ettirilmiştir.



Şekil 4.22. Abdomen Kapsül ağı ile yapılan sınıflandırma çalışması akış şeması

Çizelge 4.31. Abdomen Kapsül ağı ile yapılan sınıflandırma çalışmasında kullanılan hiper parametreler

Kayıp Fonksiyonu: <i>Dice Kayıp Fonk.</i>
Öğrenme Oranı: $10^{-3}; 10^{-5}$
Optimizasyon: <i>Adam</i>
Aktivasyon Fonksiyonu: <i>PReLU</i>
Görüntü Boyutu: <i>128</i>
Yığın Boyutu: <i>32</i>
Çapraz Doğrulama: <i>k=10</i>
Döngü: <i>100</i>

Çalışma kapsamında orijinal veri seti, İA-1, İA-2, İA-3, İA-4 ve İA-5 veri setleri ile uygulamalar yapılmıştır. Tüm veri setlerinde T1 ve T2 ağırlıklı görüntüler üzerinde yapılan çalışmalar sonucunda test görüntüleri üzerinde elde edilen ortalama test sonuçları Çizelge 4.32'de sunulmuştur.

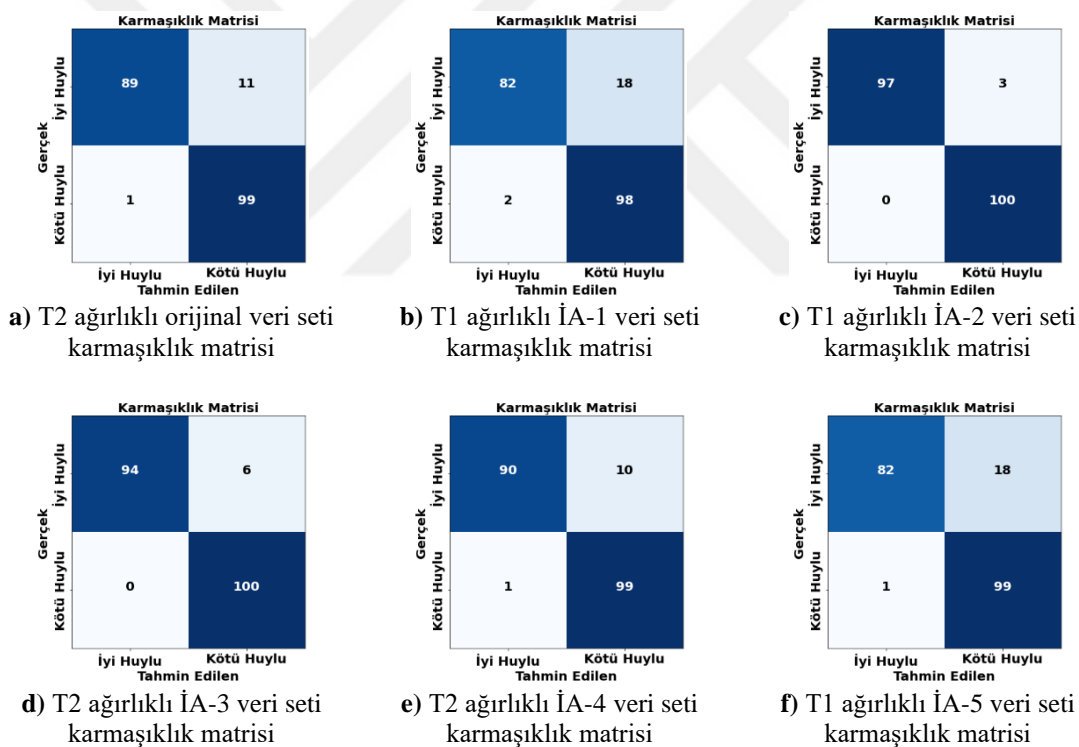
Çizelge 4.32. Abdomen Kapsül ağı ile yapılan sınıflandırma çalışmalarının ortalama test sonuçları

VERİ SETİ	MOD	DOĞ	KES	DUY	F-1 SKORU	EAA SKORU	KAPPA SKORU
ORİJİNAL	T1	0.904	0.991	0.880	0.925	0.940	0.808
	T2	0.943	0.994	0.916	0.950	0.979	0.914
İA-1	T1	0.901	0.984	0.867	0.916	0.936	0.801
	T2	0.842	0.990	0.817	0.883	0.887	0.685
İA-2	T1	0.982	0.999	0.969	0.983	0.998	0.964
	T2	0.949	0.996	0.918	0.954	0.992	0.898
İA-3	T1	0.817	0.966	0.768	0.850	0.900	0.635
	T2	0.969	0.999	0.949	0.972	0.994	0.937
İA-4	T1	0.909	0.996	0.887	0.930	0.942	0.818
	T2	0.948	0.992	0.921	0.953	0.987	0.896
İA-5	T1	0.905	0.986	0.882	0.925	0.940	0.810
	T2	0.692	0.984	0.656	0.777	0.747	0.385

Çalışmalarda her bir veri setindeki en iyi sonuçları özetlemek gerekirse, orijinal veri seti ile T2 ağırlıklı görüntülerde %94.3 doğruluk, %99.4 kesinlik, %91.6 duyarlılık, %95 F-1 skoru, %97.9 EAA skoru ve %91.4 Kappa skoru elde edilmiştir. İA-1 veri setinde T1 ağırlıklı görüntülerle doğruluk, kesinlik, duyarlılık, F-1 skoru, AUC skoru ve Kappa skoru sırasıyla 0.901, 0.984, 0.867, 0.916, 0.936 ve 0.801 olarak hesaplanmıştır. İA-2 veri setinde T1 ağırlıklı görüntüler için en iyi sonuçlar %98.2 doğruluk, %99.9 kesinlik, %96.9 duyarlılık, %98.3 F-1 skoru, %99.8 EAA skoru ve %96.4 Kappa skorudur. İA-3 ve İA-4 veri setlerinde en iyi sonuçlara T2 ağırlıklı görüntülerde ulaşılmıştır. İA-3 veri seti için doğruluk, kesinlik, duyarlılık, F-1 skoru, EAA skoru ve

Kappa skoru sırasıyla 0.969, 0.999, 0.949, 0.972, 0.994 ve 0.937 olmuştur. İA-4 veri setinde ise doğruluk, kesinlik, duyarlılık, F-1 skoru, EAA skoru ve Kappa skoru sırasıyla 0.948, 0.992, 0.921, 0.953, 0.987 ve 0.896'dır. Son olarak İA-5 veri seti ile elde edilen sonuçlar değerlendirildiğinde, T1 ağırlıklı görüntülerde %90.5 doğruluk, %98.6 kesinlik, %88.2 duyarlılık, %92.5 F-1 skoru, %94 EAA skoru ve %81 Kappa skoru elde edilmiştir.

Çizelge 4.32, farklı modların (T1-ağırlıklı/T2-ağırlıklı) genellikle farklı veri setlerinde daha başarılı sonuçlar verdiğini göstermektedir. Şekil 4.23'te her veri seti için en iyi modun karmaşıklık matrisleri verilmiştir. Her mod için en iyi sonuçlar dikkate alındığında, T1 ağırlıklı görüntüler için İA-2 veri setinde elde edilen sonuçlar en iyi performansı gösterirken, T2 ağırlıklı görüntüler için İA-3 veri setinde elde edilen sonuçlar en iyisi olarak öne çıkıyor. Sonuç olarak, en mükemmel veri seti, T1 modunda en iyi sonuçları ve T2 modunda en iyi ikinci sonuçları veren İA-2 veri setidir.



Şekil 4.23. Her İA'daki en iyi modun karmaşıklık matrisleri

Çalışmanın güvenilirliği açısından önceki çalışmalarla karşılaştırılması ve buna göre avantaj ve dezavantajlarının ortaya konulması büyük önem taşımaktadır. Bu nedenle, Çizelge 4.33'te abdomenle ilgili mevcut yayınlar ve bu yayınların sonuçları sunulmuştur. Sadece MR kullanılan çalışmaların sayısı sınırlı olduğundan karşılaştırma çeşitliliğini artırmak için BT ile yapılan çalışmalar da çizelgeye eklenmiştir.

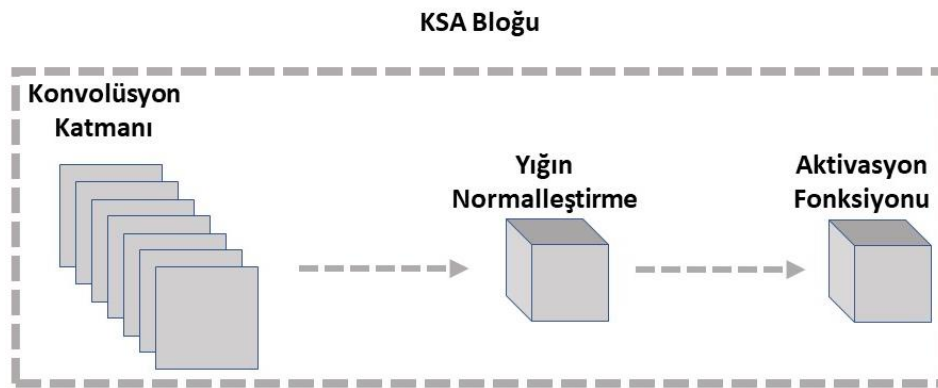
Çizelge 4.33. Abdomen görüntüleri ile yapılan sınıflandırma çalışmalarının ortalama test sonuçları

ÇALIŞMA	TOPLAM VERİ SAYISI	YÖNTEM	VERİ	ÖZG	DOĞ	KES	DUY	F-1 SKORU	EAA SKORU	KAPPA SKORU
(SAİPRASAD VE ARK., 2013)	20 (10 İYİ HUYYLU, 10 KÖTÜ HUYYLU)	RASGELE ORMAN	BT	0.8	---	---	0.9	---	---	---
(KOYUNCU VE CEYLAN, 2017)	32 (24 İYİ HUYYLU, 8 KÖTÜ HUYYLU)	PSO-YSA	DİNAMİK BT	---	0.789	---	---	---	0.842	---
(Lİ VE ARK., 2017B)	230 (121 İYİ HUYYLU, 109 KÖTÜ HUYYLU)	GSEOM	BT	---	0.8	---	---	---	---	---
(KOYUNCU VE ARK., 2019)	114 (90 İYİ HUYYLU, 24 KÖTÜ HUYYLU)	SINIRLI PSO-YSA	DİNAMİK BT	0.852	0.807	---	0.75	---	0.786	---
(FOTİ VE ARK., 2018)	129 (82 İYİ HUYYLU, 47 KÖTÜ HUYYLU)	İSTATİSTİKSEL YÖNTEMLER	BT	0.945	0.976	---	0.976	---	0.991	---
(ELMOHR VE ARK., 2019)	54 (25 ADRENAL ADENOM, 29 ADRENAL KARSİNOM)	LOJİSTİK REGRESYON	BT	0.83	0.82	---	0.81	---	0.89	---
(MOAWAD VE ARK., 2021)	40 (21 İYİ HUYYLU, 19 KÖTÜ HUYYLU)	RASGELE ORMAN	BT	0.714	---	---	0.842	---	0.850	---
(Bİ VE ARK., 2022)	229 (54 ADRENAL KARSİNOM, 35 FONKSİYONEL OLMAYAN ADRENAL ADENOM, 33 ADRENAL MYELOLİPOM, 58 GANGLİONÖROMA, 49 FEOKROMOSİTOM)	ÇOK ÖLÇEKLİ TEMSİL AĞI	BT	0.973	0.895	0.899	0.907	0.899	---	---
(KUSUNOKİ VE ARK., 2022)	107 (83 ADRENAL ADENOM, 24 ADRENAL ADENOM OLMAYAN)	Derin Konvolüsyon Sinir Ağı (DKSA)	BT	1	---	---	0.9	---	0.99	---
(LİU VE ARK., 2022)	280 (188 LİPİTTEN FAKİR ADENOM, 92 SUBKLİNİKAL FEOKROMOSİTOMLAR)	Lojistik Regresyon Destek Vektör Makinesi (DVM) Rasgele Orman	BT	0.91	0.864	---	0.815	---	0.917	---
(ROMEO VE ARK., 2018)	60 (20 LİPİTTEN ZENGİN ADENOM, 20 LİPİTTEN FAKİR ADENOM, 20 ADENOM OLMAYAN)	J48	MR	0.796	0.8	---	0.786	---	0.794	---
(BARSTUGAN VE ARK., 2019)	122 (112 İYİ HUYYLU, 10 KÖTÜ HUYYLU)	GSEOM -DVM	MR	0.9	0.984	---	0.991	---	---	---
BU ÇALIŞMA	122 (112 İYİ HUYYLU, 10 KÖTÜ HUYYLU)	ABDOMEN KAPSÜL	MR	---	0.982	0.999	0.969	0.983	0.998	0.964

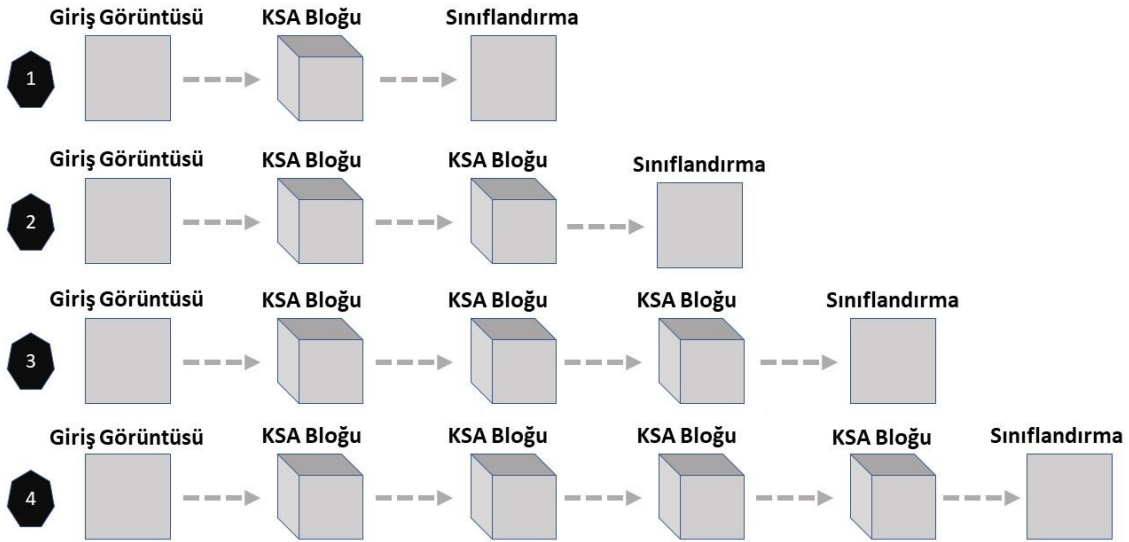
(Barstugan ve ark., 2019)'te kullanılan veri seti, çalışmamızda kullanılan veri seti ile aynıdır, bu nedenle bu iki çalışmanın karşılaştırılması özellikle değerlidir. Bu iki çalışma incelendiğinde ortak olarak doğruluk ve duyarlılık metrikleri dikkat çekmektedir. (Barstugan ve ark., 2019)'teki sınıflandırma sonuçları, doğruluk metriği ve duyarlılık metriği açısından sırasıyla %0.2 ve %2.2 daha iyidir. (Barstugan ve ark., 2019)'te yarı otomatik çerçeve kullanmak yerine MR görüntülerinden lezyonları manuel olarak seçerek ilgili çalışmalar yapılmıştır. Ancak; bu tez çalışmasında tüm lezyonlar dikkate alınarak ortak bir İA çerçevesi belirlenmiş ve görüntüler buna göre otomatik olarak çıkarılmıştır. Öte yandan, söz konusu çalışmada sadece iki metrik bu çalışma ile karşılaştırılabilmiş ve bu da yüzeysel bir karşılaştırmaya neden olmuştur. Bunun dışında, bu tez çalışmasında hemen hemen tüm değerlendirme ölçütleri açısından literatürdeki diğer çalışmalardan açıkça daha iyi performans göstermektedir.

4.4.3.2. KSA kullanılarak gerçekleştirilen sınıflandırma çalışması

Bu çalışma için oluşturulan temel KSA bloğu Şekil 4.24'te verilmiştir. Burada yapı konvolüsyon, yığın normalleştirme ve aktivasyon fonksiyonu katmanlarından oluşmaktadır. Veri boyutunu küçültmesine rağmen öznelik kaybına neden olabileceğinden havuzlama katmanı tercih edilmemiştir. Bunun yerine, çıkarılan özellik haritalarını normalleştiren yığın normalleştirme kullanılmıştır. Şekil 4.25'te bu çalışmada kullanılan bir veya daha fazla temel KSA bloğundan oluşan yapılar verilmiştir.



Şekil 4.24. KSA bloğu



Şekil 4.25. Çalışmada kullanılan KSA yapıları

Konvolüsyon katmanında, farklı filtre boyutları ve filtre sayıları kullanılarak model parametrelerinin modelin sınıflandırma performansı üzerindeki etkileri gözlemlenmiştir. Yığın normalleştirme bölümünde, bir önceki bölümde çıkarılan özellik haritaları ortalama ve standart sapmaya göre normalleştirilir. Son kısımda ise ReLU aktivasyon fonksiyonundan geçirilerek sınıflandırma aşamasına geçilir. Sınıflandırma aşamasında *Softmax* aktivasyon fonksiyonu yardımıyla görüntüler ilgili sınıflara ayrılır.

Çalışmada veri seti olarak bir önceki çalışmada en iyi sonuçları veren İA-2 (Veri setindeki tüm kitleleri kapsayan en küçük ilgi alanı) veri seti belirlenmiştir. Derin öğrenme çalışmalarında sıklıkla karşılaşılan aşırı uydurma problemini önlemek için İA verilerine yine veri artırma işlemi uygulanmıştır. Burada tıbbi görüntülere uygun olan yükseklik kaydırma, genişlik kaydırma, döndürme gibi yöntemler kullanılmıştır. Bu şekilde 112 iyi huylu, 10 kötü huylu kitleden oluşan veri seti her sınıf için 1000 adet olmak üzere toplam 2000 adet görüntü elde edilerek veri seti genişletilmiştir. Çalışmanın tüm aşamalarında, bu veri setinin %75'i eğitim için, %25'i doğrulama için rastgele ayrılmıştır. Ayrıca modellerin eğitim sonrası performanslarını test etmek için eğitim aşamasında ağın görmediği iyi huylu ve kötü huylu görüntülerle test işlemleri gerçekleştirilmiştir. Tüm eğitim ve test süreçleri MATLAB üzerinde gerçekleştirilmiştir.

İlk olarak sabit sayıda filtre belirlenmiş ve farklı filtre boyutları için ağ eğitimleri gerçekleştirilmiştir. Buradaki amaç, en iyi sonuçları veren filtre boyutunu bulmaktır. Eğitim sürecinden sonra gerçekleştirilen test aşamasında elde edilen test sonuçları Çizelge 4.34'te verilmiştir. Bu çizelgede de görüldüğü gibi filtre boyutları 5 ve 9

seçildiğinde test doğruluğu 0.97'ye ulaşmakta ve en başarılı sonuçlar elde edilmektedir. Diğer metriklerle karşılaştırıldığında bu iki değer birbirlerine karşı net bir üstünlük sağlayamazlar. Sınıflandırma çalışmalarında doğrulukla birlikte eğitim süresi de önemli bir kriter olduğundan, aynı doğruluk değerlerine sahip bu iki parametreyi eğitim süresine göre karşılaştırmak daha doğru olacaktır. Bu nedenle, eğitim sürelerine göre daha küçük filtre boyutuna sahip 5 seçildiğinde aynı doğruluk daha kısa sürede elde edilmiştir. Bu nedenle çalışmanın bundan sonraki bölümünde filtre boyutu 5 seçilerek işleme devam edilecektir. Bu değer için doğruluk, duyarlılık, özgüllük, kesinlik, F-1 skoru ve EAA skoru sırasıyla 0.97, 0.90, 0.98, 0.90, 0.90 ve 0.94 olarak elde edilmiştir.

Çizelge 4.34. Tek KSA bloğu için farklı filtre boyutlarında test sonuçları

[Filtre Boyutu Filtre Sayısı]	DOĞ	DUY	ÖZG	KES	F-1 Skoru	EAA Skoru	Eğitim Süresi
[3 20]	0.91	0.70	0.95	0.70	0.70	0.82	3 dk 5 sn
[4 20]	0.54	1	0.46	0.24	0.38	0.73	3 dk 14 sn
[5 20]	0.97	0.90	0.98	0.90	0.90	0.94	3 dk 25 sn
[6 20]	0.85	0.80	0.86	0.50	0.62	0.83	3 dk 33 sn
[7 20]	0.55	1	0.47	0.24	0.39	0.74	3 dk 48 sn
[8 20]	0.83	0.90	0.81	0.45	0.60	0.86	4 dk 48 sn
[9 20]	0.97	0.80	1	1	0.89	0.90	4 dk 43 sn
[10 20]	0.90	0.70	0.93	0.64	0.67	0.82	5 dk 7 sn
[11 20]	0.83	0.90	0.81	0.45	0.60	0.86	6 dk 24 sn
[12 20]	0.75	0.80	0.75	0.35	0.45	0.77	6 dk 49 sn
[13 20]	0.88	0.70	0.92	0.58	0.64	0.81	7 dk 16 sn

Kullanılacak filtre boyutuna karar verildikten sonra bu sefer filtre sayısı üzerinde çalışmalar yapılmıştır. Farklı filtre sayıları ile yapılan eğitimler sonrasında test görüntüleri üzerinde elde edilen sonuçlar Çizelge 4.35'te paylaşılmıştır. Bu çizelgede hem 20 hem de 25 filtre sayısı seçildiğinde en iyi sonuçların alındığı görülmektedir. Metrik sonuçları her iki filtre sayısı değeri için de aynı olduğundan, eğitim süresi yine belirleyici rol oynayacaktır. Benzer sonuçlara daha kısa sürede ulaştığı için filtre sayısı olarak 20 seçilmesi daha uygun görülmüştür.

Çizelge 4.35. Tek KSA bloğu için farklı filtre sayılarında test sonuçları

[Filtre Boyutu Filtre Sayısı]	DOĞ	DUY	ÖZG	KES	F-1 Skoru	EAA Skoru	Eğitim Süresi
[5 5]	0.95	1	0.95	0.77	0.87	0.97	1 dk 14 sn
[5 10]	0.90	0.90	0.90	0.60	0.72	0.90	1 dk 46 sn
[5 15]	0.90	0.80	0.91	0.62	0.70	0.86	2 dk 27 sn
[5 20]	0.97	0.90	0.98	0.90	0.90	0.94	3 dk 25 sn
[5 25]	0.97	0.90	0.98	0.90	0.90	0.94	4 dk 10 sn
[5 30]	0.93	0.60	0.98	0.86	0.71	0.79	4 dk 38 sn
[5 35]	0.90	0.80	0.92	0.62	0.70	0.86	5 dk 25 sn
[5 40]	0.88	0.90	0.88	0.56	0.69	0.89	6 dk 18 sn
[5 45]	0.88	0.70	0.92	0.58	0.64	0.81	8 dk 16 sn
[5 50]	0.91	0.60	0.97	0.75	0.67	0.78	8 dk 43 sn

Tek KSA bloğu ile yapılan çalışmalar sonucunda en iyi performansın [5 20] filtresi ile elde edildiği görülmüştür. Bir sonraki bölümde, Şekil 4.25'te gösterildiği gibi tek bir KSA bloğu yerine birden çok KSA bloğundan oluşan ağların kullanılmasının performans üzerindeki etkisi değerlendirilmiştir. Bu amaçla iki, üç ve dört KSA bloğundan oluşan ağ yapıları kullanılmıştır. Bu aşamada elde edilen test sonuçları Çizelge 4.36'da verilmiştir. Çizelgede model numaraları Şekil 4.25'te belirtilen ağları temsil etmektedir. Test doğruluğunun iki KSA bloğu kullanıldığında 0.94, üç KSA bloğu kullanıldığında 0.91 ve dört KSA bloğu kullanıldığında 0.97 olduğu görülmektedir. İkili ve üçlü KSA blokları kullanıldığında test doğruluğunun sırasıyla %3 ve %6 oranında düştüğü görülmektedir. Öte yandan, dört KSA bloğu kullanıldığında, tek bir KSA bloğu kullanıldığında elde edilen sonucun aynısı elde edilmiştir. Ancak eğitim süreleri açısından karşılaştırıldığında, dört KSA bloğu tek bir KSA bloğuna göre daha derindir ve daha fazla hesaplama gerektirir, bu nedenle daha uzun bir eğitim süresi ile aynı sonuca ulaşırlar. Eğitim süresi açısından iki ağ arasında yaklaşık yedi kat fark vardır. Bu, aynı test doğruluğuna sahip iki ağ arasında tek bir KSA bloğu kullanımının daha avantajlı olduğunu açıkça göstermektedir.

Çizelge 4.36. Farklı sayıda KSA blokları için test sonuçları

Model Numarası	DOĞ	DUY	ÖZG	KES	F-1 Skoru	EAA Skoru	Eğitim Süresi
1	0.97	0.90	0.98	0.90	0.90	0.94	3 dk 25 sn
2	0.94	0.60	1	1	0.75	0.80	9 dk 27 sn
3	0.91	0.80	0.93	0.67	0.72	0.87	15 dk 39 sn
4	0.97	0.80	1	1	0.89	0.90	22 dk 46 sn

Sonuç olarak, uygulanan üç farklı senaryo arasından en iyi sonuçların tek bir KSA bloğu kullanıldığında [5 20] filtresi ile elde edildiği tablolardan açıkça görülmektedir. Bu parametreler için elde edilen doğruluk, duyarlılık, özgülük, kesinlik, F-1 skoru ve EAA skoru sırasıyla 0.97, 0.90, 0.98, 0.90, 0.90 ve 0.94 olarak elde edilmiştir. Bunlara ek olarak test görüntüleri üzerinde elde edilen karmaşıklık matrisi Şekil 4.26'da verilmiştir. Karmaşıklık matrisinde görüldüğü gibi 59 adet iyi huylu test görüntüsünden sadece biri, 10 adet kötü huylu test görüntüsünden sadece 1 tanesi yanlış sınıflandırılmıştır. Bu da modelin üstünlüğünü desteklemektedir.

		Karmaşıklık Matrisi	
		Kötü Huylu	İyi Huylu
Gerçek	Kötü Huylu	9	1
	İyi Huylu	1	58
		Kötü Huylu Tahmin Edilen	İyi Huylu Tahmin Edilen

Şekil 4.26. [5 20] filtresi için karmaşıklık matrisi

Yapay zekâ alanındaki gelişmelere paralel olarak BDT sistemleri kullanılarak radyolojik kesitsel görüntülerden adrenal kitlelerin saptanması da artmıştır. Hem makine öğrenmesi hem de derin öğrenme yöntemleri bu çalışmalara öncülük etmektedir. Çizelge 4.37'de bu çalışmada elde edilen sonuçların yanı sıra radyolojik görüntülerden ikili adrenal lezyon sınıflandırması üzerine önceki çalışmaların sonuçları sunulmuştur. Sınıflandırma çalışmalarında öncelikli olarak dikkate alınan doğruluk metriği açısından, bu çalışmada elde edilen 0.97 doğruluk oranı diğerlerinden çok daha üstündür. Diğer metriklerle karşılaştırıldığında bu çalışmanın her metrikte üstün olduğu açıkça görülmektedir.

Çizelge 4.37. Önceki çalışmalarla karşılaştırma

Çalışma	DOĞ	DUY	ÖZG	KES	F-1 Skoru	EAA Skoru
(Lİ VE ARK., 2017B)	0.80	---	---	---	---	---
(ROMEO VE ARK., 2018)	0.80	0.79	0.80	---	---	0.79
(ELMOHR VE ARK., 2019)	0.82	0.81	0.83	---	---	0.89
(KOYUNCU VE ARK., 2019)	0.80	0.75	0.82	---	---	0.78
(LİU VE ARK., 2022)	0.86	0.81	0.91	---	---	0.91
*BU ÇALIŞMA	0.97	0.90	0.98	0.90	0.90	0.94

4.5. Pnömoni Veri Setiyle Yapılan Çalışmalar

Zatürre, akciğerlerin akut solunum yolu enfeksiyonlarından biridir. Akciğerler, sağlıklı bir insan nefes aldığı anda havayla dolan alveol adı verilen küçük keselerden oluşur. Bir kişi zatürre olduğunda, alveoller, nefes almayı ağırlı hale getiren ve oksijen alımını sınırlayan irin ve sıvı ile doldurulur. Zatürre, dünya çapında çocuklarda en büyük bulaşıcı ölüm nedenidir. 2019 yılında, 5 yaş altı 740180 çocuğun ölümüne neden olmuştur ve bu beş yaşın altındaki tüm ölümlerin %14'ünü, 1-5 yaş arası çocuklarda ise tüm ölümlerin %22'sini oluşturmaktadır (World Health Organization, 2022).

Zatürrenin erken teşhisi ve tedavisi, çocukların sağlığı için büyük önem taşımaktadır. Tanı için sıklıkla kullanılan teknolojilerden biri de röntgendir. Radyologlar, röntgen görüntüleri yardımıyla bir hastanın zatürre olup olmadığını kolayca teşhis edebilir. Ancak artan çalışma saatleri ve yorgunluk radyologların işini zorlaştırmaktadır. BDT sistemleri, özellikle son otuz yılda yapay zekanın hızlanmasıyla popüler hale geldi. Birçok yapay zeka modeli uzmanlara çok yakın çıkarımlar yapmaktadır (Ronneberger ve ark., 2015; Badrinarayanan ve ark., 2017; Wang ve ark., 2020).

Tez çalışması kapsamında, çocuklarda meydana gelen zatürrenin hızlı, doğru ve otomatik teşhisini sağlamak amacıyla bir sınıflandırma modeli geliştirilmiştir.


4.5.1. Pnömoni veri setiyle yapılan sınıflandırma çalışması

Tez çalışması kapsamında yapılan çalışmada, beş yaş altı çocuklardan alınan röntgen görüntülerinden zatürre-sağlıklı sınıflandırması yapılmıştır. Göğüs röntgeni veri seti, Guangzhou Kadın ve Çocuk Tıp Merkezi'nde 1-5 yaş aralığındaki pediatrik hastalardan oluşan retrospektif bir gruptan seçilmiştir (Kermany ve ark., 2018). Çalışmada klasik KSA'da havuzlama katmanında meydana gelen kayıpları gidermek amacıyla kapsül ağlar kullanılmıştır. Ayrıca veri seti dağılımındaki heterojenliği ortadan kaldırmak ve çalışma performansını artırmak için veri setine k-kat ÇD uygulanmıştır. Çalışmanın literatüre katkıları şu şekildedir:

- KSA mimarisi yerine kapsül ağlar kullanılarak havuzlama sürecinde veri kaybının önüne geçilmiştir.
- K-katlı çapraz doğrulama kullanılarak çalışma performansı artırılmış ayrıca veri seti ayırmada oluşan heterojenlik giderilmiştir.
- Görüntü iyileştirme uygulanarak çalışma sonuçları iyileştirilmiştir.

- Çalışmanın sonuçları literatürdeki çalışmalarla karşılaştırılmış ve daha iyi performanslar göstermiştir.

Pnömoni tespiti için çalışmaya özgü olarak geliştirilen “Göğüs Kapsül” yapısı Şekil 4.27’de sunulmuştur. Bu yapı Abdomen Kapsül yapısıyla eşittir. Farklı veri setlerinde yapının nasıl çalıştığının test edilmesi amacıyla iki veri setinde de kullanılmıştır. Yine burada giriş görüntüsü öncelikli olarak 32 adet 5x5 lik konvolüsyon filtrelerinden geçirilip sonrasında *PReLU* aktivasyon fonksiyonundan geçirilerek ilk konvolüsyon katmanı sonunda özellik haritaları oluşturulur. Sonrasında bu özellik haritaları yine 32 adet bu kez 9x9 luk konvolüsyon filtrelerinden geçirilir ve kapsüllere göre yeniden şekillendirilerek birincil kapsül katmanını oluştururlar. Birincil kapsül katmanındaki kapsüller ile abdomen kapsül katmanında bulunan sınıf sayısına göre belirlenen yüksek seviye kapsüller arasında dinamik yönlendirme algoritmasına kapsül çıkışı ve ağırlık güncellemesi işlemi gerçekleştirilir. Çıkışta tam bağlantılı katman (TBK) bölümünde ardışık iki TBK ve aktivasyon fonksiyonu olarak *PReLU* seçilmiştir. Son bölümde ikili sınıflandırma için sınıf tahmini yapıldığından Sigmoid aktivasyon fonksiyonu kullanılmıştır.



Şekil 4.27. Pnömoni sınıflandırması için kullanılan Göğüs Kapsül ağ modeli

Çalışmada öncelikle önerilen kapsül ağı yapısı mevcut veri seti ile eğitildi. Eğitim ve test için veri ayrımı sırasında ÇD kullanılacağından eğitim (1349 adet sağlıklı, 3883 adet zatürre) ve test (234 adet sağlıklı, 390 adet zatürre) için ayrılan veri setleri birleştirildi. ÇD için $k=10$ olarak seçilmiştir. Böylece çalışmada 1583 adet sağlıklı, 4273 adet zatürre olmak üzere toplam 5856 adet akciğer röntgen görüntüsü kullanıldı. Eğitimler sırasında kullanılan yığın boyutu olarak 256 seçilmiştir. Eğitimler referans kaynaklarda yer alan çalışmalar dikkate alınarak 50 döngü boyunca devam etti (Baydilli ve Atila, 2020). Optimizasyon yöntemi olarak *Adam* seçilmiş, öğrenme oranı 10^{-3} olarak seçilmiş ve kayıp fonksiyonunda ilerleme olmazsa 3 döngü sonra öğrenme oranı %10

azaltılmış ve nihai öğrenme oranı 10^{-5} olarak belirlenmiştir. Çizelge 4.38’de çalışmada kullanılan parametreler paylaşılmıştır.

Çizelge 4.38. Pnömoni sınıflandırma çalışmasında kullanılan hiper parametreler

Kayıp Fonksiyonu: <i>İkili Çapraz Entropi</i>
Öğrenme Oranı: 10^{-3} ; 10^{-5}
Optimizasyon: <i>Adam</i>
Aktivasyon Fonksiyonu: <i>PReLU</i>
Görüntü Boyutu: 128
Yığın Boyutu: 256
Çapraz Doğrulama: k=10
Döngü Sayısı: 50

Orijinal görüntüler ile yapılan çalışmalar tamamlandıktan sonra KSUHE uygulanmış görüntülerle aynı parametreler ve model üzerinde eğitimler gerçekleştirilmiştir. Şekil 4.28’de orijinal görüntülere KSUHE uygulanması sonucunda elde edilen görüntülere ait örnekler verilmiştir.



Şekil 4.28. a) Sağlıklı Görüntü, b) Sağlıklı KSUHE Görüntüsü, c) Zatürre Görüntüsü, d) Zatürre KSUHE Görüntüsü

4.5.1. Pnömoni veri setiyle yapılan sınıflandırma çalışmasının sonuçları

Çalışmada öncelikle orijinal veri seti ile eğitimler gerçekleştirilmiştir. Veri seti 10 kat çapraz doğrulama ile 10 parçaya ayrılmış, 1 parça test için ayrılmış ve kalan 9 parça eğitimde kullanılmıştır. Eğitimde kullanılan verilerin %20’si de doğrulama için ayrılmıştır. Çizelge 4.39 eğitim, doğrulama ve test için kullanılan görüntülerin sayısını göstermektedir. Her kat ÇD’nin sonunda, eğitilen ağ, ayrı test görüntüleri ile test edilmiş

ve performans metrikleri ile değerlendirilmiştir. Son olarak, her kat ÇD’da elde edilen metrik sonuçlarının ortalamaları alınmıştır.

Çizelge 4.39. Pnömoni sınıflandırma çalışmasında eğitim, doğrulama ve test için ayrılan veri sayıları

Eğitim veri seti sayısı	Doğrulama veri seti sayısı	Test veri seti sayısı
4216	1054	586


Eğitimler sonucunda her iki veri setinde de test görüntüleri üzerinde Göğüs Kapsül ağ yapısıyla elde edilen ortalama sonuçlar Çizelge 4.40’ta paylaşılmıştır. İlk satır, orijinal veri seti ile çalışmada elde edilen sonuçları içermektedir. Burada doğruluk, kesinlik, duyarlılık, F1-skor ve EAA skorları sırasıyla 0.838, 0.789, 0.784, 0.786, 0.971 olarak elde edilmiştir. İkinci satırda ise veri setine KSUHE uygulandıktan sonra yapılan eğitim sonucunda elde edilen sonuçlar yer almaktadır. Burada doğruluk, kesinlik, duyarlılık, F1-skor ve EAA skorları sırasıyla 0.988, 0.994, 0.998, 0.991, 0.998 olarak elde edildi. Çizelge incelendiğinde, KSUHE uygulanmış görüntülerle yapılan çalışmanın daha başarılı sonuçlar verdiği görülmüştür.

Çizelge 4.40. Göğüs Kapsül ağı ile yapılan pnömoni sınıflandırma çalışması ortalama test sonuçları

Veri Seti	DOĞ	KES	DUY	F1-Skor	EAA
Orijinal Veri seti	0.838	0.789	0.784	0.786	0.971
KSUHE Uygulanan Veri seti	0.988	0.994	0.988	0.991	0.988

Çalışmanın ikinci aşamasında, ilk aşamada en iyi sonucu elde ettiğimiz KSUHE uygulanmış veri setiyle literatürde son dönemlerde en çok kullanılan derin öğrenme modelleri eğitilmiş ve sonuçlar önerilen modelle karşılaştırılmıştır. Karşılaştırma için InceptionV3 (Szegedy ve ark., 2016), Xception (Chollet, 2017), DenseNet121 (Huang ve ark., 2017) modelleri kullanılmıştır. İlk bölümde olduğu gibi 10 kat ÇD ile çalışmalar gerçekleştirilmiş ve her metrik için ortalamalar alınmıştır.

Şekil 4.29’da önerilen model ve diğer modellerin karşılaştırmaları her bir metrik için grafiksel olarak sunulmuştur. Grafikler incelendiğinde her bir metrik bazında önerilen Göğüs-Kapsül yapısı diğerlerine bariz bir şekilde üstünlük sağlamıştır. Ayrıca Şekil 4.30’da her bir modelin test görüntüleri üzerinde elde edilen karmaşıklık matrisleri verilmiştir. Yine burada da 158 sağlıklı hastadan sadece 1’ini, 428 pnömoni hastasından da sadece 9’unu yanlış tespit eden Göğüs Kapsül modeli diğer modellere bariz üstünlük sağlamıştır.



Şekil 4.29. Tüm modellerin metrik karşılaştırmaları (a) Test doğruluğu, b) Test kesinliği c) Test duyarlılığı, d) Test F1-skoru, e) Test EAA skoru)

Karmaşıklık Matrisi

Gerçek	Sağlıklı	157	1
	Pnömoni	9	419
		Sağlıklı	Pnömoni
		Tahmin Edilen	

a) Göğüs-Kapsül karmaşıklık matrisi

Karmaşıklık Matrisi

Gerçek	Sağlıklı	38	120
	Pnömoni	24	404
		Sağlıklı	Pnömoni
		Tahmin Edilen	

b) Inception V3 karmaşıklık matrisi

Karmaşıklık Matrisi

Gerçek	Sağlıklı	24	134
	Pnömoni	18	410
		Sağlıklı	Pnömoni
		Tahmin Edilen	

c) Xception karmaşıklık matrisi

Karmaşıklık Matrisi

Gerçek	Sağlıklı	138	20
	Pnömoni	116	312
		Sağlıklı	Pnömoni
		Tahmin Edilen	

d) ResNet-121 karmaşıklık matrisi

Şekil 4.30. Tüm modellerin karmaşıklık matrisleri (a) Göğüs-Kapsül karmaşıklık matrisi, b) Inception V3 karmaşıklık matrisi c) Xception karmaşıklık matrisi, d) ResNet-121 karmaşıklık matrisi)

Son olarak çalışmada elde edilen sonuçlar literatürdeki çalışmalar ve yöntemlerle karşılaştırılmıştır. Karşılaştırılan tüm çalışmalarda, Guangzhou Kadın ve Çocuk Tıp Merkezi'nden 1-5 yaş aralığındaki pediatrik hastalardan oluşan göğüs röntgeni veri setinin kullanılmış olduğu dikkate alınmalıdır. Çizelge 4.41'de her çalışmada karşılaştırılan ve önerilen modeller ayrı ayrı verilmiştir. Karşılaştırma için her çalışmada farklı metrikler kullanıldığından, çalışmamızı daha fazla çalışma ile karşılaştırmak için beş farklı metrik kullanılmıştır.

Çizelge 4.41'de görülebileceği gibi, önerilen model doğruluk, kesinlik ve F1-skoru değerlerinde diğerlerinden çok daha iyidir. (Chouhan ve ark., 2020) çalışmasında duyarlılık ve EAA skor değerleri için daha iyi sonuçlar elde etmiştir. Ancak, bu metriklerde bir sonraki en iyi skorlar önerilen modele aittir ve bu metriklerde iki çalışma arasında çok az fark vardır. Çizelgede görüldüğü üzere literatürdeki çalışmalarda genel olarak değiştirilmiş KSA ağırları ve farklı transfer öğrenme ağırları kullanılmıştır. Kapsül

ağı ilk defa tez çalışmasında önerilmiş ve diğerlerinden daha iyi performans sergilediği gösterilmiştir. Bu tez çalışmasında önerilen Göğüs Kapsül modelinin yeniliğini, doğruluğunu, güvenilirliğini ve karşılaştırılabilirliğini göstermektedir.

Çizelge 4.41. Pnömoni sınıflandırma çalışması literatür karşılaştırması

Çalışma	Model	Veri Artırımı	Çapraz Doğrulama	DOĞ	KES	DUY	F1 Skoru	EAA Skoru
(Kerem ve ark., 2018)	InceptionV3	Belirtilmemiş	Yok	0.928	-	0.932	-	0.968
(Rajaraman ve ark., 2018)	Önerilen VGG16	Belirtilmemiş	Yok	0.957	0.951	0.983	0.967	0.990
	Ardışık KSA			0.943	0.920	0.980	0.957	0.983
	Artık KSA			0.910	0.908	0.954	0.931	0.967
	Inception KSA			0.886	0.887	0.939	0.913	0.922
(Ayan ve Ünver, 2019)	Xception	Var	Yok	0.820	-	0.850	-	-
	VGG16			0.870	-	0.820	-	-
(Saraiva ve ark., 2019)	Önerilen KSA	Yok	5 kat ÇD	0.953	-	-	-	-
(Stephen ve ark., 2019)	Önerilen KSA	Var	Yok	0.937	-	-	-	-
(Gülğün ve Hamza, 2020)	Önerilen KSA	Var	Yok	0.934	-	-	--	-
(Liang ve Zheng, 2020)	Önerilen KSA	Var	Yok	0.905	0.891	0.967	0.927	0.953
	VGG 16			0.742	0.723	0.951	0.822	0.840
	DenseNet121			0.819	0.792	0.964	0.869	0.769
	InceptionV3			0.853	0.916	0.841	0.877	0.655
	Xception			0.878	0.857	0.967	0.908	0.930
(Chouhan ve ark., 2020)	AlexNet	Var	Yok	0.928	0.902	0.989	-	0.978
	DenseNet121			0.926	0.911	0.992	-	0.987
	InceptionV3			0.920	0.903	0.984	-	0.973
	GoogLeNet			0.931	0.904	0.994	-	0.982
	ResNet18			0.942	0.915	0.994	-	0.993
	Birleşik model			0.963	0.932	0.996	-	0.993
(Çınar ve ark., 2021)	Geliştirilen Model	Belirtilmemiş	Yok	0.971	-	0.957	0.945	-
	DenseNet201			0.968	-	0.953	0.937	-
	ResNet50			0.963	-	0.929	0.929	-
	Inceptionv3			0.953	-	0.976	0.943	-
	GoogleNet			0.940	-	0.865	0.887	-
	AlexNet			0.910	-	0.983	0.792	-
(Manickam ve ark., 2021)	ResNet50	Var	Yok	0.930	0.889	0.967	0.927	0.930
	InceptionV3			0.929	0.887	0.927	0.906	0.910
	InceptionResNet V2			0.924	0.888	0.932	0.909	0.910
Bu Çalışma	InceptionV3	Yok	10 kat ÇD	0.754	0.945	0.770	0.848	0.701
	Xception			0.741	0.958	0.754	0.843	0.666
	DenseNet121			0.768	0.941	0.729	0.819	0.746
	Göğüs-Kapsül*			0.984	0.996	0.971	0.983	0.974

5. SONUÇLAR VE ÖNERİLER

Tez çalışmasında farklı medikal görüntü türlerinde sınıflandırma ve segmentasyon çalışmaları gerçekleştirilmiştir. Her bir görüntü türü için ayrı çalışmalar yapılmış olup bunlara özgü BDT sistemleri geliştirilmiştir. Sınıflandırma çalışmalarında mamogram, abdomen ve zatürre veri setleri kullanılmış olup segmentasyon çalışmaları için abdomen ve polip veri setlerinden faydalanılmıştır. Her bir çalışmaya dair gerçekleştirilen işlemler ilgili veri setinin alt başlığı altında anlatılmıştır.

Sonuçlar bölümünde önerilen BDT sistemleri ile elde edilen bulguların detaylı bir analizi sunulmuştur. Her bir çalışma kendi içerisinde değerlendirilip avantaj ve dezavantajları, çalışmaların öne çıkan yönleri vurgulanmıştır. Öneriler kısmında ise tez çalışması neticesinde elde edilen kazanımlar ışığında gelecekte yapılacak olan çalışmalara yol gösterecek önerilere yer verilmiştir.

5.1. Sonuçlar

Önerilen BDT sistemlerinin sonuçlarını her bir veri seti için ayrı ayrı değerlendirmek daha anlamlı olacaktır. Bu yüzden sonuçlar mamogram, abdomen, polip ve zatürre veri setleri için olmak üzere dört ayrı kısımda incelenecektir.

Mamogram veri setiyle yapılan çalışmalarda öncelikle görüntülerde gereksiz harf-rakam gibi teşhis aşamasında işimize yaramayacak kısımlar elimine edilerek temizlenmiş, sadece kitlenin olduğu kısım alınıp arka plan atılarak da kesilmiş olarak adlandırılan iki ayrı veri seti elde edilmiştir. Sınıflandırma aşamasında görüntüler ağa verilmeden önce veri artırımı yapılarak aşırı öğrenme ve ezberlemenin önüne geçilmiştir. Sınıflandırma için oluşturulan bir KSA yapısının yanı sıra farklı ağlarla transfer öğrenimi gerçekleştirilmiştir. Transfer öğrenimi kısmında hem ağdaki konvolüsyon katmanları dondurulup sadece sınıflandırma katmanını probleme uyarlayarak özellik çıkarımı yapılmış hem de sınıflandırma katmanının yanı sıra ağdaki birkaç konvolüsyon katmanının çözülerek hassas ayar ile yeniden eğitimi işlemleri gerçekleştirilmiştir. Çalışma sonucunda veri setleri bakımından kesilmiş diye tanımladığımız veri setiyle yapılan çalışmaların en iyi sonuçları verdiği, transfer öğrenimi kısmında ise özellik çıkarımı yapılarak eğitilen ağların hassas ayar yapılarak eğitilen ağlara göre daha başarılı sonuçlar verdiği gözlemlenmiştir.

Abdomen veri setiyle T1 ve T2 ağırlıklı görüntülerle hem sınıflandırma hem de segmentasyon çalışmaları gerçekleştirilmiştir. Sınıflandırma çalışmalarında KSA ve kapsül ağlar temelli olmak üzere iki ayrı çalışma yapılmıştır. Kapsül ağ temelli model kullandığımız çalışmada öncelikle çalışma performansına etkisini gözlemlemek amacıyla farklı boyutlarda ilgi alanları çıkarılmış ve bunlar için ayrı veri setleri oluşturulmuştur. Bu işlem sırasında tüm görüntülerdeki lezyonları içerecek şekilde belirlenen çerçeveler esas alınmıştır. Eğitim aşamasında medikal görüntülerde veri sayısı azlığından ötürü meydana gelen 10-kat ÇD kullanılmış olup ezberleme-aşırı uydurmayı engellemek amacıyla veri artırımı yapılmıştır. Sınıflandırma için çalışmaya özgü bir Abdomen Kapsül modeli geliştirilmiştir. Veri setleri bu modelde eğitilmiştir. Çalışma sonucunda en iyi sonuçları veren veri setinin tüm lezyonları içine alacak minimum çerçeve boyutuyla çıkarılan veri seti olduğu görülmüştür. Yapılan diğer sınıflandırma çalışmasında en iyi sonucun elde edildiği veri seti kullanılarak sınıflandırma çalışması bu kez KSA temelli ağ yapıları üzerinde gerçekleştirilmiştir. Bu çalışmada ilk olarak bir konvolüsyon katmanı, yığın normalleştirme ve sınıflandırma katmanından oluşan konvolüsyon bloğu oluşturulmuştur. Bu blok kullanılarak optimum filtre boyutu-filtre sayısı çiftini bulmak amacıyla farklı denemeler yapılmıştır. Elde edilen bulgular neticesinde bulunan optimum filtre boyutu-filtre sayısı çifti farklı sayılardaki konvolüsyon bloklarıyla denenmiştir. Burada ağ derinliğinin eğitim performansına etkisi gözlemlenmiştir. Yapılan çalışmalar neticesinde en iyi sonuçlar hem tek katmanlı blokta hem de dört katmanlı blokta elde edilmiştir. Eğitim süresi bakımından tek katmanlı blok dört katmanlı bloğa göre daha kısa sürede aynı başarıyı gösterdiğinden çalışma sonucunda en iyi ağ yapısının tek katmanlı blok olduğu görülmüştür. Hem KSA hem de kapsül ağ temelli gerçekleştirilen sınıflandırma çalışmaları neticesinde kapsül ağ kullanılarak yapılan eğitimler sonucunda elde edilen sonuçların daha başarılı olduğu görülmüştür.

Abdomen veri setiyle yapılan segmentasyon çalışmasında derinlemesine bir analiz yapılmıştır. Burada öncelikle görüntülere ADD, KSUHE ve füzyon gibi ön işlemler uygulanmış, eğitim aşamasında farklı k-kat ÇD ve yığın boyutu sayıları kullanılarak bunların performansa etkisi gözlemlenmiş ve orijinal U-Net modelinde kullanılan İÇE kayıp fonksiyonu yerine Dice kayıp fonksiyonu, konvolüsyon katmanlarında ise ReLU aktivasyon fonksiyonu yerine PReLU aktivasyon fonksiyonu kullanılarak modifiye edilmiş U-Net modeli geliştirilmiştir. Yapılan çalışmalar neticesinde en iyi sonuçların T1 ağırlıklı görüntülere ADD uygulanan veri setinde modifiye edilmiş U-Net modeli kullanıldığında ve 3-kat ÇD, yığın boyutu 1 seçildiğinde

elde edildiği görülmüştür. Yapılan çalışmalar farklı en iyi modeller, kayıp fonksiyonları kullanılan modellerle karşılaştırılmış ve onlardan daha üstün olduğu değerlendirme metrikleriyle elde edilen sonuçlarla anlaşılmıştır.

Polip veri setiyle gerçekleştirilen segmentasyon çalışmalarında bir önceki çalışmada olduğu gibi ADD, AKD, KSUHE gibi farklı ön işlemler uygulanarak veri setleri oluşturulmuş ve bu ön işlem yöntemleri kıyaslanmıştır. Eğitim aşamasında U-Net ve bir önceki çalışmada da bahsedilen modifiye edilmiş U-Net modelinin yanı sıra kodlayıcı kısımda farklı ağlar kullanılarak transfer öğrenmesi yapılan modeller geliştirilmiştir. Abdomen segmentasyon çalışmasına benzer şekilde farklı k-kat ÇD ve yığın boyutları incelenmiştir. Yapılan çalışma sonucunda en iyi sonuçların ADD kullanılan 4-kat ÇD ve yığın boyutu 1 seçildiğinde elde edildiği gözlemlenmiştir. Çalışma farklı kayıp fonksiyonları kullanılan modeller ve veri setleriyle tekrarlanmış ve yaptığımız çalışmanın başarısı gözler önüne serilmiştir.

Zatürre veri setiyle yapılan çalışmada çocuklarda meydana gelen zatürreyi tespit etmek amacıyla röntgen görüntüleri üzerinde sınıflandırma çalışmaları gerçekleştirilmiştir. Yapılan çalışmada görüntülere KSUHE ön işlemi uygulanarak ham veri setinden farklı bir veri seti elde edilmiştir. Eğitim için kapsül ağ temelli bir Göğüs Kapsül modeli geliştirilmiş ve 10-kat ÇD kullanılmıştır. Yapılan eğitimler sonucunda en iyi sonuçların KSUHE uygulanan veri setiyle elde edildiği görülmüştür.

Gerçekleştirilen tez çalışmasının literatüre katkıları şu şekilde özetlenebilir:

- Ham veri seti yerine ilgi alanı çıkarılmış ve/veya farklı ön işlem uygulanan veri setleriyle yapılan çalışmaların daha başarılı sonuçlar verdiği tespit edilmiştir.
- Yapılan k-kat ÇD ve yığın boyutu analizleri neticesinde genel olarak k değeri arttığında ve yığın boyutu azaldığında en başarılı sonuçların elde edildiği görülmüştür.
- Gerçekleştirilen tüm sınıflandırma çalışmalarında kapsül ağ tabanlı modellerin KSA tabanlı modellere göre daha iyi performans sergilediği gözlemlenmiştir.
- Segmentasyon çalışmalarında U-Net üzerinde gerçekleştirilen farklı modifikasyonların çalışma performansını önemli ölçüde geliştirdiği sonucuna varılmıştır.

- Kapsül ağlarla gerçekleştirilen segmentasyon çalışmalarında elde edilen sonuçların U-Net ile elde edilen sonuçlara nazaran daha düşük olsa da gelecekteki çalışmalar açısından umut vadettiği görülmüştür.
- Tezin geneline bakıldığında kapsül ağların sınıflandırma çalışmalarında literatürde yer alan en son modelleri geride bıraktığı, segmentasyon çalışmaları için geliştirilebilecek yönleri olduğu tespit edilmiştir.

5.2. Öneriler

Tez çalışması kapsamında gerçekleştirilen çalışmalar ve yapılan uygulamalar sonucunda aşağıdaki önerilerin gelecekte yapılacak olan çalışmalar için faydalı olacağı düşünülmektedir:

- Donanımsal yetersizlikten dolayı hem görüntü boyutları hem de çalışmada kullanılan farklı parametrelerde belirli bir değerin üzerinde denemeler yapılamamıştır. Daha güçlü bir donanımla yapılamayan denemeler gerçekleştirilebilir.
- Kapsül ağların sınıflandırma görevlerinde 2-boyutlu görüntülerde elde ettiği başarılar tez boyunca aktarılmıştır. Bu bakımdan 3-boyutlu görüntüler kullanılarak gerçekleştirilecek olan sınıflandırma çalışmalarında da başarılı performanslar sergileyebilir.
- Kapsül ağların segmentasyon çalışmalarında kullanımı ile elde edilen sonuçların iyileştirilmesi için daha detaylı analizler yapılabilir.

KAYNAKLAR

- Afshar, P., Heidarian, S., Naderkhani, F., Oikonomou, A., Plataniotis, K. N. ve Mohammadi, A., 2020, Covid-caps: A capsule network-based framework for identification of covid-19 cases from x-ray images, *Pattern Recognition Letters*, 138, 638-643.
- Ahmed, N., Natarajan, T. ve Rao, K. R., 1974, Discrete Cosine Transform, *IEEE Transactions on Computers*, C-23 (1), 90-93.
- Ayan, E. ve Ünver, H. M., 2019, Diagnosis of pneumonia from chest X-ray images using deep learning, *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*, 1-5.
- Badrinarayanan, V., Kendall, A. ve Cipolla, R., 2017, Segnet: A deep convolutional encoder-decoder architecture for image segmentation, *IEEE transactions on pattern analysis and machine intelligence*, 39 (12), 2481-2495.
- Banik, D., Bhattacharjee, D. ve Nasipuri, M., 2020, A multi-scale patch-based deep learning system for polyp segmentation, In: *Advanced Computing and Systems for Security*, Eds: Springer, p. 109-119.
- Bardhi, O., Sierra-Sosa, D., Garcia-Zapirain, B. ve Elmaghraby, A., 2017, Automatic colon polyp detection using Convolutional encoder-decoder model, *2017 IEEE international symposium on signal processing and information technology (ISSPIT)*, 445-448.
- Barstugan, M., Ceylan, R., Asoglu, S., Cebeci, H. ve Koplay, M., 2019, Adrenal Tumor Classification on T1 and T2-weighted Abdominal MR Images, *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 1-7.
- Barstugan, M., Ceylan, R., Asoglu, S., Cebeci, H. ve Koplay, M., 2020, Adrenal tumor characterization on magnetic resonance images, *International Journal of Imaging Systems and Technology*, 30 (1), 252-265.
- Barstuğan, M., Ceylan, R., Asoglu, S., Cebeci, H. ve Koplay, M., 2018, Adrenal tumor segmentation method for MR images, *Computer methods and programs in biomedicine*, 164, 87-100.
- Baydilli, Y. Y. ve Atila, Ü., 2020, Classification of white blood cells using capsule networks, *Computerized Medical Imaging and Graphics*, 80, 101699.
- Bernal, J., Sánchez, F. J., Fernández-Esparrach, G., Gil, D., Rodríguez, C. ve Vilariño, F., 2015, WM-DOVA maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians, *Comput Med Imaging Graph*, 43, 99-111.
- Bernal, J., Tajkbaksh, N., Sánchez, F. J., Matuszewski, B. J., Chen, H., Yu, L., Angermann, Q., Romain, O., Rustad, B. ve Balasingham, I., 2017, Comparative validation of polyp detection methods in video colonoscopy: results from the MICCAI 2015 endoscopic vision challenge, *IEEE transactions on medical imaging*, 36 (6), 1231-1249.
- Bi, L., Kim, J., Su, T., Fulham, M., Feng, D. ve Ning, G., 2017, Adrenal lesions detection on low-contrast CT images using fully convolutional networks with multi-scale integration, *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, 895-898.
- Bi, L., Kim, J., Su, T., Fulham, M., Feng, D. D. ve Ning, G., 2022, Deep multi-scale resemblance network for the sub-class differentiation of adrenal masses on computed tomography images, *Artificial Intelligence in Medicine*, 132, 102374.
- Brandao, P., Mazomenos, E., Ciuti, G., Calìo, R., Bianchi, F., Mencias, A., Dario, P., Koulaouzidis, A., Arezzo, A. ve Stoyanov, D., 2017, Fully convolutional neural

- networks for polyp segmentation in colonoscopy, *Medical Imaging 2017: Computer-Aided Diagnosis*, 101340F.
- Chai, H., Guo, Y. ve Wang, Y., 2015, Automatic segmentation of adrenal tumor in CT images based on sparse representation, *Journal of Medical Imaging and Health Informatics*, 5 (8), 1737-1741.
- Chen, L.-C., Papandreou, G., Schroff, F. ve Adam, H., 2017, Rethinking atrous convolution for semantic image segmentation, *arXiv preprint arXiv:1706.05587*.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F. ve Adam, H., 2018, Encoder-decoder with atrous separable convolution for semantic image segmentation, *Proceedings of the European conference on computer vision (ECCV)*, 801-818.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Chouhan, V., Singh, S. K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., Damaševičius, R. ve De Albuquerque, V. H. C., 2020, A novel transfer learning based approach for pneumonia detection in chest X-ray images, *Applied Sciences*, 10 (2), 559.
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T. ve Ronneberger, O., 2016, 3D U-Net: learning dense volumetric segmentation from sparse annotation, *International conference on medical image computing and computer-assisted intervention*, 424-432.
- Çınar, A., Yıldırım, M. ve Eroğlu, Y., 2021, Classification of Pneumonia Cell Images Using Improved ResNet50 Model, *Traitement du Signal*, 38 (1).
- Deng, F., Pu, S., Chen, X., Shi, Y., Yuan, T. ve Pu, S., 2018, Hyperspectral image classification with capsule network using limited training samples, *Sensors*, 18 (9), 3153.
- Duraisamy, S. ve Emperumal, S., 2017, Computer-aided mammogram diagnosis system using deep learning convolutional fully complex-valued relaxation neural network classifier, *IET Computer Vision*, 11 (8), 656-662.
- Elmohr, M., Fuentes, D., Habra, M., Bhosale, P., Qayyum, A., Gates, E., Morshid, A., Hazle, J. ve Elsayes, K., 2019, Machine learning-based texture analysis for differentiation of large adrenal cortical tumours on CT, *Clinical radiology*, 74 (10), 818. e811-818. e817.
- Foti, G., Malleo, G., Faccioli, N., Guerriero, A., Furlani, L. ve Carbognin, G., 2018, Characterization of adrenal lesions using MDCT wash-out parameters: diagnostic accuracy of several combinations of intermediate and delayed phases, *La radiologia medica*, 123 (11), 833-840.
- Gereige, R. S. ve Laufer, P. M., 2013, Pneumonia, *Pediatrics in review*, 34 (10), 438-456.
- Gonzalez, R. C., Woods, R.E. , 2008, Digital Image Processing (2nd Edition), New Jersey: Pearson Prentice Hall, p.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. ve Bengio, Y., 2014, Generative adversarial nets, *Advances in neural information processing systems*, 2672-2680.
- Gøtzsche, P. C. ve Jørgensen, K. J., 2013, Screening for breast cancer with mammography, *Cochrane database of systematic reviews* (6).
- Guan, S. ve Loew, M., 2017, Breast Cancer Detection Using Transfer Learning in Convolutional Neural Networks, *2017 IEEE Applied Imagery Pattern Recognition Workshop (AIPR)*, 1-8.

- Gülgün, O. D. ve Hamza, E., 2020, Classification performance comparisons of deep learning models in pneumonia diagnosis using chest x-ray images, *Turkish Journal of Engineering*, 4 (3), 129-141.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- He, Y., Qin, W., Wu, Y., Zhang, M., Yang, Y., Liu, X., Zheng, H., Liang, D. ve Hu, Z., 2020, Automatic left ventricle segmentation from cardiac magnetic resonance images using a capsule network, *Journal of X-ray Science and Technology*, 28 (3), 541-553.
- Hepsağ, P. U., Özel, S. A. ve Yazıcı, A., 2017, Using deep learning for mammography classification, *2017 International Conference on Computer Science and Engineering (UBMK)*, 418-423.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. ve Adam, H., 2017, Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv:1704.04861*.
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q., 2017, Densely connected convolutional networks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708.
- Huttenlocher, D. P., Klanderman, G. A. ve Rucklidge, W. J., 1993, Comparing images using the Hausdorff distance, *IEEE transactions on pattern analysis and machine intelligence*, 15 (9), 850-863.
- International, W. C. R. F., 2019, Worldwide cancer data, <https://www.wcrf.org/dietandcancer/cancer-trends/worldwide-cancer-data>:
- Jha, D., Smedsrud, P. H., Riegler, M. A., Halvorsen, P., de Lange, T., Johansen, D. ve Johansen, H. D., 2020, Kvasir-seg: A segmented polyp dataset, *International Conference on Multimedia Modeling*, 451-462.
- Kang, J. ve Gwak, J., 2019, Ensemble of instance segmentation models for polyp segmentation in colonoscopy images, *IEEE Access*, 7, 26440-26447.
- Kavitha, T., Mathai, P. P., Karthikeyan, C., Ashok, M., Kohar, R., Avanija, J. ve Neelakandan, S., 2021, Deep learning based capsule neural network model for breast cancer diagnosis using mammogram images, *Interdisciplinary Sciences: Computational Life Sciences*, 1-17.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X. ve Yan, F., 2018, Identifying medical diagnoses and treatable diseases by image-based deep learning, *Cell*, 172 (5), 1122-1131. e1129.
- Koresh, H. J. D., Chacko, S. ve Periyayagi, M., 2021, A modified capsule network algorithm for oct corneal image segmentation, *Pattern Recognition Letters*, 143, 104-112.
- Koyuncu, H. ve Ceylan, R., 2017, Classification of adrenal lesions by bounded PSO-NN, *2017 25th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Koyuncu, H., Ceylan, R., Erdogan, H. ve Sivri, M., 2018, A novel pipeline for adrenal tumour segmentation, *Computer methods and programs in biomedicine*, 159, 77-86.
- Koyuncu, H., Ceylan, R., Asoglu, S., Cebeci, H. ve Koplay, M., 2019, An extensive study for binary characterisation of adrenal tumours, *Medical & biological engineering & computing*, 57 (4), 849-862.

- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.
- Kusunoki, M., Nakayama, T., Nishie, A., Yamashita, Y., Kikuchi, K., Eto, M., Oda, Y. ve Ishigami, K., 2022, A deep learning-based approach for the diagnosis of adrenal adenoma: a new trial using CT, *The British Journal of Radiology*, 95, 20211066.
- LaLonde, R., Xu, Z., Irmakci, I., Jain, S. ve Bagci, U., 2021, Capsules for biomedical image segmentation, *Medical image analysis*, 68, 101889.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. ve Jackel, L. D., 1989, Backpropagation applied to handwritten zip code recognition, *Neural computation*, 1 (4), 541-551.
- LeCun, Y., Jackel, L., Bottou, L., Brunot, A., Cortes, C., Denker, J., Drucker, H., Guyon, I., Muller, U. ve Sackinger, E., 1995, Comparison of learning algorithms for handwritten digit recognition, *International conference on artificial neural networks*, 53-60.
- Li, B., Ge, Y., Zhao, Y., Guan, E. ve Yan, W., 2018, Benign and malignant mammographic image classification based on convolutional neural networks, *Proceedings of the 2018 10th International Conference on Machine Learning and Computing*, 247-251.
- Li, Q., Yang, G., Chen, Z., Huang, B., Chen, L., Xu, D., Zhou, X., Zhong, S., Zhang, H. ve Wang, T., 2017a, Colorectal polyp segmentation using a fully convolutional neural network, *2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, 1-5.
- Li, X., Guindani, M., Ng, C. ve Hobbs, B., 2017b, Classification of adrenal lesions through spatial Bayesian modeling of GLCM, *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, 147-151.
- Liang, G. ve Zheng, L., 2020, A transfer learning method with deep residual network for pediatric pneumonia diagnosis, *Computer methods and programs in biomedicine*, 187, 104964.
- Liu, H., Guan, X., Xu, B., Zeng, F., Chen, C., Yin, H. L., Yi, X., Peng, Y. ve Chen, B. T., 2022, Computed Tomography-Based Machine Learning Differentiates Adrenal Pheochromocytoma From Lipid-Poor Adenoma, *Frontiers in endocrinology*, 13, 833413.
- Mallat, S., 1988, Review of multifrequency channel decompositions of images and wavelet models, *Scholar select*, p.
- Manickam, A., Jiang, J., Zhou, Y., Sagar, A., Soundrapandiyar, R. ve Samuel, R. D. J., 2021, Automated pneumonia detection on chest X-ray images: A deep learning approach with different optimizers and transfer learning architectures, *Measurement*, 184, 109953.
- Mendiratta-Lala, M., Avram, A., Turcu, A. F. ve Dunnick, N. R., 2017, Adrenal imaging, *Endocrinology and Metabolism Clinics*, 46 (3), 741-759.
- Moawad, A. W., Ahmed, A., Fuentes, D. T., Hazle, J. D., Habra, M. A. ve Elsayes, K. M., 2021, Machine learning-based texture analysis for differentiation of radiologically indeterminate small adrenal tumors on adrenal protocol CT scans, *Abdominal Radiology*, 46 (10), 4853-4863.
- Nguyen, Q. ve Lee, S.-W., 2018, Colorectal segmentation using multiple encoder-decoder network in colonoscopy images, *2018 IEEE first international conference on artificial intelligence and knowledge engineering (AIKE)*, 208-211.

- Oktaý, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y. ve Kainz, B., 2018, Attention u-net: Learning where to look for the pancreas, *arXiv preprint arXiv:1804.03999*.
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G. ve Antani, S., 2018, Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs, *Applied Sciences*, 8 (10), 1715.
- Romeo, V., Maurea, S., Cuocolo, R., Petretta, M., Mainenti, P. P., Verde, F., Coppola, M., Dell'Aversana, S. ve Brunetti, A., 2018, Characterization of adrenal lesions on unenhanced MRI using texture analysis: a machine-learning approach, *Journal of Magnetic Resonance Imaging*, 48 (1), 198-204.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Ruuska, S., Hämäläinen, W., Kajava, S., Mughal, M., Matilainen, P. ve Mononen, J., 2018, Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle, *Behavioural processes*, 148, 56-62.
- Saber, A., Sakr, M., Abo-Seida, O. M., Keshk, A. ve Chen, H., 2021, A novel deep-learning model for automatic detection and classification of breast cancer using the transfer-learning technique, *IEEE Access*, 9, 71194-71209.
- Sabour, S., Frosst, N. ve Hinton, G. E., 2017, Dynamic routing between capsules, *Advances in neural information processing systems*, 3856-3866.
- Saiprasad, G., Saenz, N., Chang, C. ve Siegel, E., 2010, Prototype Decision Support System for Evaluation of Adrenal Glands Incorporated into Routine CT Workflow, *Radiological Society of North America Scientific Assembly and Annual Meeting*.
- Saiprasad, G., Chang, C.-I., Safdar, N., Saenz, N. ve Siegel, E., 2013, Adrenal gland abnormality detection using random forest classification, *Journal of digital imaging*, 26 (5), 891-897.
- Saraiva, A. A., Ferreira, N. M. F., de Sousa, L. L., Costa, N. J. C., Sousa, J. V. M., Santos, D., Valente, A. ve Soares, S., 2019, Classification of Images of Childhood Pneumonia using Convolutional Neural Networks, *Bioimaging*, 112-119.
- Silva, J., Histace, A., Romain, O., Dray, X. ve Granado, B., 2014, Toward embedded detection of polyps in WCE images for early diagnosis of colorectal cancer, *Int J Comput Assist Radiol Surg*, 9 (2), 283-293.
- Simonyan, K. ve Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*.
- Society, A. C., 2020, Breast Cancer Facts & Figures, *Atlanta American Cancer Society:2019-2020*.
- Solomon, C. ve Breckon, T., 2011, Fundamentals of Digital Image Processing: A practical approach with examples in Matlab, John Wiley & Sons, p.
- Stephen, O., Sain, M., Maduh, U. J. ve Jeong, D.-U., 2019, An efficient deep learning approach to pneumonia classification in healthcare, *Journal of healthcare engineering*, 2019.
- Suckling, J., 1994, The mammographic image analysis society digital mammogram database, *Digital Mammo*, 375-386.
- Sun, L., Wang, J., Hu, Z., Xu, Y. ve Cui, Z., 2019, Multi-View Convolutional Neural Networks for Mammographic Image Classification, *IEEE Access*, 7, 126273-126282.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.
- Szegedy, C., Ioffe, S., Vanhoucke, V. ve Alemi, A. A., 2017, Inception-v4, inception-resnet and the impact of residual connections on learning, *Thirty-First AAAI Conference on Artificial Intelligence*.
- Tang, S., Guo, Y., Wang, Y., Cao, W. ve Sun, F., 2014, Segmentation and 3D visualization of pheochromocytoma in contrast-enhanced CT images, *2014 International Conference on Audio, Language and Image Processing*, 39-43.
- Teo, C. K., 2003, Digital enhancement of night vision and thermal images, *NAVAL POSTGRADUATE SCHOOL MONTEREY CA*.
- Van Rijn, J. C., Reitsma, J. B., Stoker, J., Bossuyt, P. M., Van Deventer, S. J. ve Dekker, E., 2006, Polyp miss rate determined by tandem colonoscopy: a systematic review, *Official journal of the American College of Gastroenterology/ ACG*, 101 (2), 343-350.
- Vlaardingerbroek, M. T. ve Boer, J. A., 2013, Magnetic resonance imaging: theory and practice, Springer Science & Business Media, p.
- Wang, L., Lin, Z. Q. ve Wong, A., 2020, Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images, *Scientific Reports*, 10 (1), 1-12.
- World Health Organization, W., 2022, Pneumonia, <https://www.who.int/news-room/fact-sheets/detail/pneumonia>: [May 20, 2022].
- Yoon, H., Han, Y. ve Hahn, H., 2009, Image contrast enhancement based sub-histogram equalization technique without over-equalization noise, *World Academy of Science, Engineering and Technology*, 50, 2009.
- Zade, A. A. T., Aziz, M. J., Masoudnia, S., Mirbagheri, A. ve Ahmadian, A., 2022, An improved capsule network for glioma segmentation on MRI images: A curriculum learning approach, *Computers in Biology and Medicine*, 148, 105917.
- Zhao, W., He, H., Zhao, J. ve Sun, J., 2019, Adrenal Tumor Vessels Segmentation Using Convolutional Neural Network in Computed Tomography Angiography, *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 1006-1009.
- Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N. ve Liang, J., 2018, Unet++: A nested u-net architecture for medical image segmentation, In: *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, Eds: Springer, p. 3-11.
- Zisserman, K. S. a. A., 2015, Very Deep Convolutional Networks for Large-Scale Image Recognition, *International Conference on Learning Representations*.
- Zoph, B., Vasudevan, V., Shlens, J. ve Le, Q. V., 2018, Learning transferable architectures for scalable image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 8697-8710.

EKLER

