



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



MEDİKAL GÖRÜNTÜLERDE
NOKTA BULUTU UYGULAMALARI

Hasan Basri ÖKSÜZ

DOKTORA TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Aralık-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Hasan Basri ÖKSÜZ tarafından hazırlanan “Medikal Görüntülerde Nokta Bulutu Uygulamaları” adlı tez çalışması 28/11/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Seral ÖZŞEN
(Konya Teknik Üniversitesi)

.....

Danışman

Prof. Dr. Rahime CEYLAN
(Konya Teknik Üniversitesi)

.....

Üye

Doç. Dr. Muhammet Üsame ÖZİÇ
(Pamukkale Üniversitesi)

.....

Üye

Doç. Dr. Sabri ALTUNKAYA
(Necmettin Erbakan Üniversitesi)

.....

Üye

Dr. Öğr. Üyesi Kemal ERDOĞAN
(Konya Teknik Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

Bu tez çalışması tarafından nolu proje ile desteklenmiştir.

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.

İmza

Hasan Basri ÖKSÜZ

Tarih:

ÖZET

DOKTORA TEZİ

MEDİKAL GÖRÜNTÜLERDE NOKTA BULUTU UYGULAMALARI

Hasan Basri ÖKSÜZ

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

Danışman: Prof. Dr. Rahime CEYLAN

2025, 138 Sayfa

Jüri

**Prof. Dr. Rahime CEYLAN
Prof. Dr. Seral ÖZŞEN
Doç. Dr. Muhammet Üsame ÖZİÇ
Doç. Dr. Sabri ALTUNKAYA
Dr. Öğr. Üyesi Kemal ERDOĞAN**

Bu tez çalışmasında, böbrek ve pankreas segmentasyonu problemleri voksel tabanlı ve nokta bulutu tabanlı derin öğrenme yöntemleri kullanılarak kapsamlı biçimde incelenmiştir. Çalışma, veri temsiline bağlı olarak modellerin performans ve genelleme yeteneklerini değerlendirmeyi amaçlamaktadır. Böbrek segmentasyonu için iki aşamalı kaba–ince segmentasyon çerçevesi tasarlanmıştır; U-Net, AttUNet, ResUNet, MFFAU-Net ve TransUNet mimarileri KiTS19, KiTS23 ve FLARE22 veri setleri üzerinde test edilmiştir. Sonuçlar, voksel tabanlı yöntemlerin yüksek doğruluk sunduğunu ancak hesaplama maliyeti ve genelleme kabiliyeti açısından sınırlılıklar taşıdığını göstermiştir. Bu sınırlılıklara yanıt olarak, nokta bulutu tabanlı PointNet ve DGKSA mimarileri değerlendirilmiş; bu modellerin düşük bellek kullanımı ve güçlü geometrik farkındalık özellikleriyle özellikle karmaşık organ sınırlarında başarılı sonuçlar verdiği gözlemlenmiştir. DGKSA modeli, pankreas segmentasyonunda voksel tabanlı yöntemlere göre daha üstün doğruluk elde etmiştir. Genel olarak, çalışma tıbbi görüntü segmentasyonunda nokta bulutu temsiline dayalı yaklaşımların uygulanabilirliğini sistematik biçimde ortaya koymakta ve veri temsili–performans ilişkisine dair özgün bulgular sunarak gelecekteki araştırmalara yön göstermektedir.

Anahtar Kelimeler: Derin Öğrenme, Medikal Görüntü Segmentasyonu, Nokta Bulutu Tabanlı Modeller, Voksel Tabanlı Modeller, PointNet, DGKSA

ABSTRACT

PhD THESIS

POINT CLOUD APPLICATIONS IN MEDICAL IMAGES

Hasan Basri ÖKSÜZ

**Konya Technical University
Institute of Graduate Studies
Department of Electrical and Electronics Engineering**

Advisor: Prof. Dr. Rahime CEYLAN

2025, 138 Pages

Jury

Prof. Dr. Rahime CEYLAN

Prof. Dr. Seral ÖZŞEN

Assoc. Prof. Dr. Muhammet Üsame ÖZİÇ

Assoc. Prof. Dr. Sabri ALTUNKAYA

Assist. Prof. Dr. Kemal ERDOĞAN

This thesis comprehensively investigates kidney and pancreas segmentation problems using voxel-based and point cloud-based deep learning methods. The study aims to evaluate the impact of data representation on model performance and generalization capability. For kidney segmentation, two-stage coarse-to-fine framework was designed, and architectures including U-Net, AttUNet, ResUNet, MFFAU-Net, and TransUNet were tested on KiTS19, KiTS23, and FLARE22 datasets. The results demonstrated that voxel-based methods achieve high accuracy but remain limited by computational cost and generalization challenges. To address these limitations, point cloud-based architectures, PointNet and DGCNN, were explored. These models achieved competitive results, benefiting from low memory usage and strong geometric awareness, particularly in delineating complex organ boundaries. The DGCNN model achieved superior accuracy compared to voxel-based methods in pancreas segmentation. Overall, this study systematically demonstrates the applicability of point cloud-based representations for medical image segmentation and provides novel insights into the relationship between data representation and model performance, offering valuable guidance for future research.

Keywords: Deep Learning, Medical Image Segmentation, Point Cloud-Based Models, Voxel-Based Models, PointNet, DGCNN

ÖNSÖZ

Lisansüstü eğitim sürecim boyunca bilimsel bakış açısı kazanmamda, araştırma disiplininin gelişmesinde ve tez çalışmamın şekillenmesinde değerli bilgi birikimi ve rehberliğiyle her zaman yanımda olan danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Bölümü öğretim üyesi Prof. Dr. Rahime CEYLAN'a en içten teşekkürlerimi sunarım.

Bu süreçte sabrı, desteği ve anlayışıyla her zaman yanımda olan eşim Fatma ÖKSÜZ'e; maddi ve manevi katkılarıyla güç veren aileme içten teşekkür ederim.

Hasan Basri ÖKSÜZ
KONYA-2025



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
2.1. Abdomen Segmentasyonu Üzerine Literatür Çalışmaları.....	5
2.2. Böbrek Segmentasyonu Üzerine Literatür Çalışmaları.....	7
2.3. Pankreas Segmentasyonu Üzerine Literatür Çalışmaları	9
2.4. Nokta Bulutu Uygulamaları Üzerine Literatür Çalışmaları	12
3. MATERYAL VE YÖNTEM.....	15
3.1. PointNet ile Sınıflandırma Uygulamaları.....	16
3.1.1. Kullanılan veri setleri.....	17
3.1.1.1. ModelNet10 veri seti	17
3.1.1.2. ModelNet40 veri seti	18
3.1.1.3. 3B MNIST veri seti.....	19
3.1.2. PointNet mimarisi	20
3.1.2.1. PointNet mimarisinin dönüşümlere karşı değişmezliği	22
3.1.2.2. PointNet mimarisinin permütasyon değişmezliği.....	23
3.1.3. Sınıflandırma problemlerinde kullanılan değerlendirme metrikleri	24
3.1.4. Deneysel tasarım.....	25
3.2. Abdomen Segmentasyonu.....	25
3.2.1. Abdomen segmentasyonunda kullanılan veri seti	28
3.2.2. Bağlantılı bileşenler analizi	30
3.2.3. 3B U-Net.....	31
3.2.4. Segmentasyonda kullanılan değerlendirme metrikleri	32
3.2.5. Kayıp fonksiyonları	35
3.2.6. Deneysel tasarım.....	37
3.3. Böbrek Segmentasyonu.....	38
3.3.1. Kullanılan veri setleri.....	39
3.3.1.1. Kits19 veri seti	39
3.3.1.2. Kits23 veri seti	40
3.3.1.3. FLARE22 veri seti	40
3.3.2. Böbrek kaba segmentasyonu	41
3.3.2.1. Birinci yaklaşım.....	42
3.3.2.2. İkinci yaklaşım.....	43
3.3.3. Böbrek ince segmentasyonu	45
3.3.3.1. Voksel tabanlı derin öğrenme yaklaşımı	45

3.3.3.2. Nokta bulutu tabanlı yaklaşım	46
3.3.3.2.1. PointNet segmentasyon ağı	49
3.3.3.2.2. DGKSA mimarisi	51
3.3.3.3. Yama (patch) tabanlı derin öğrenme yaklaşımı	53
3.4. Pankreas Segmentasyonu	54
3.4.1. Veri setleri	57
3.4.1.1. MSD Task07 Pankreas veri seti	58
3.4.1.2. FLARE22 veri seti	58
3.4.2. Kullanılan mimariler ve özellikleri	59
3.4.2.1. 3B ResUNet	59
3.4.2.2. 3B TransUNet	62
3.4.3. Kaba segmentasyon	64
3.4.4. İnce segmentasyon	65
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	68
4.1. PointNet ile Sınıflandırma Sonuçları	69
4.2. Abdomen Segmentasyonu Sonuçları	73
4.2.1. Klasik eğitime ait nicel sonuçlar	74
4.2.2. Çapraz doğrulama ile eğitime ait nicel sonuçlar	77
4.2.3. İA kırpma işleminden elde edilen nicel sonuçlar	81
4.2.4. Görsel sonuçlar	82
4.3. Böbrek Kaba Segmentasyon Sonuçları	87
4.3.1. Birinci yaklaşım sonuçları	88
4.3.1.1. İA kırpma işleminden elde edilen nicel sonuçlar	89
4.3.2. İkinci yaklaşım sonuçları	90
4.3.2.1. İA kırpma işleminden elde edilen nicel sonuçlar	92
4.4. Böbrek İnce Segmentasyon Sonuçları	93
4.4.1. 3B U-Net ile böbrek segmentasyonu sonuçları	93
4.4.2. Yama tabanlı 3B ağlarla ince segmentasyon sonuçları	98
4.4.3. Nokta bulutu tabanlı ağlar ile ince segmentasyon sonuçları	107
4.5. Pankreas Segmentasyonu Sonuçları	114
4.5.1. Kaba segmentasyon sonuçları	114
4.5.2. Pankreas İA kırpma işleminden elde edilen nicel sonuçlar	115
4.5.3. Pankreas ince segmentasyonu sonuçları	115
4.5.3.1. Voksel tabanlı mimarilerin sonuçları	115
4.5.3.2. Nokta bulutu tabanlı mimarilerin ince segmentasyon sonuçları	118
5. SONUÇLAR VE ÖNERİLER	121
5.1. Sonuçlar	122
5.1.1. Abdomen segmentasyonu sonuçları	122
5.1.2. Böbrek segmentasyonu sonuçları	124
5.1.3. Pankreas segmentasyonu sonuçları	126
5.1.4. Segmentasyon modellerinin hesaplama maliyetlerinin analizi	128
5.2. Öneriler	130
KAYNAKLAR	131

SİMGELER VE KISALTMALAR

Simgeler

d	:	Girdi hacminin veya görüntü bloğunun derinlik (depth) boyutu
h	:	Girdi hacminin veya görüntü bloğunun yükseklik (height) boyutu
n	:	Nokta sayısı
w	:	Girdi hacminin veya görüntü bloğunun genişlik (width) boyutu
x	:	Noktanın kartezyen koordinat sistemindeki x eksenine karşılık gelen konumu
y	:	Noktanın kartezyen koordinat sistemindeki y eksenine karşılık gelen konumu
z	:	Noktanın kartezyen koordinat sistemindeki z eksenine karşılık gelen konumu



Kısaltmalar

2B	: 2 boyutlu
3B	: 3 boyutlu
AO	: Azaltım oranı
AttUNet	: Attention U-Net (Dikkat Mekanizmalı U-Net)
BBA	: Bağlantılı Bileşenler Analizi
BT	: Bilgisayarlı Tomografi
CAD	: Computer-Aided Design
ÇD	: Çapraz doğrulama
ÇKA	: Çok Katmanlı Algılayıcı
DBK	: Dice Benzerlik Katsayısı
DGKSA	: Dinamik Grafik Konvolüsyonel Sinir Ağı
DKF	: Dice Kayıp Fonksiyonu
DN	: Doğru negatif
DP	: Doğru pozitif
TEA	: Tam Evrişimsel Ağ
FDK	: Fokal Dice Katsayısı
FKF	: Fokal Kayıp Fonksiyonu
FLARE22	: 2022 Fast and Low-resource semi-supervised Abdominal oRgan sEgmentation
FTK	: Fokal Tversky Katsayısı
FTKF	: Fokal Tversky Kayıp Fonksiyonu
GHF	: Görelî Hacimsel Fark
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
HM	: Hausdorff Mesafesi
HM95	: Hausdorff Mesafesi'nin yüzde 95'lik sınır değeri
İA	: İlgi Alanı
Jİ	: Jaccard İndeksi
KBT	: Kontrastlı Bilgisayarlı Tomografi
Kits19	: 2019 Kidney Tumor Segmentation
Kits23	: 2023 Kidney Tumor Segmentation
KNN	: K-en yakın komşu
KSA	: Konvolüsyonel Sinir Ağı
MFFAU-Net	: Multi-scale Feature Fusion Attention U-Net (Çok Ölçekli Özellik Füzyonuna Dayalı Dikkatli U-Net)
mm	: Milimetre
MRG	: Manyetik Rezonans Görüntüleme
Ort	: Ortalama
OSYM	: Ortalama Simetrik Yüzey Mesafesi
ÖO	: Öğrenme oranı
ResUNet	: Residual U-Net (Artık Öğrenme Tabanlı U-Net)
RNN	: Tekrarlayan Sinir Ağı
Std	: Standart sapma
TransUNet	: Transformer-based U-Net (Dönüştürücü Tabanlı U-Net)
TSA	: Tekrarlayan Sinir Ağı
YB	: Yığın boyutu
YN	: Yanlış negatif
YP	: Yanlış pozitif

1. GİRİŞ

Tıbbi görüntüleme, modern klinik pratiğin ve medikal araştırmaların temel taşlarından birini oluşturmaktadır. Bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MRG), ultrason ve diğer ileri görüntüleme yöntemleri, organ ve dokuların üç boyutlu yapısını yüksek çözünürlükte ortaya koyarak klinik tanı, tedavi planlaması ve operasyon sonrası takip süreçlerinde kritik rol üstlenmektedir (Hussain ve ark., 2022). Özellikle BT ve MRG gibi volümetrik veri üreten yöntemler, iç organların detaylı morfolojik ve yapısal analizine imkân tanımakta; bu sayede klinisyenlere daha güvenilir karar destek mekanizmaları sunmaktadır. Ancak bu yüksek çözünürlüklü hacimsel verilerin manuel olarak segmentasyonu, ciddi ölçüde zaman ve uzmanlık gerektirmekte; ayrıca gözlemciye bağımlı olması nedeniyle tekrarlanabilirlik ve güvenilirlik açısından sorunlar yaratmaktadır (Pandey ve Gupta, 2022; Xu ve ark., 2024). Aynı organın farklı gözlemciler tarafından yapılan segmentasyonları arasında belirgin varyasyonlar oluşabilmekte, bu da klinik uygulamalar açısından standardizasyonu zorlaştırmaktadır (Pandey ve Gupta, 2022).

Bu sınırlılıklar, tıbbi görüntü segmentasyonunun otomatikleştirilmesine yönelik araştırmaları hızlandırmış ve son yıllarda derin öğrenme tabanlı yaklaşımlar bu alanda ön plana çıkmıştır. Özellikle Konvolüsyonel Sinir Ağları'nın (KSA'ların) 3 Boyutlu (3B) uzantıları, organ ve lezyon segmentasyonu için yüksek doğruluk oranlarına ulaşmıştır (Asadpour ve ark., 2021; Kanaujia ve ark., 2024; Roth ve ark., 2018). Bu bağlamda 3B U-Net mimarisi, simetrik kodlayıcı-kod çözücü yapısı ve çok ölçekli atlama bağlantıları sayesinde, organ yapılarının hiyerarşik ve çok ölçekli özelliklerini etkin biçimde modelleyebilmekte ve literatürde referans bir yöntem olarak yaygın biçimde kullanılmaktadır (Çiçek ve ark., 2016; Pandey ve Gupta, 2022). Bununla birlikte, voksel tabanlı yöntemlerin büyük ölçekli 3B verilerle çalışırken yüksek bellek tüketimi ve hesaplama maliyeti doğurduğu bilinmektedir (Liu ve ark., 2017; Rayed ve ark., 2024). Bu durum, hesaplama verimliliği ile doğruluk arasında denge kurabilen alternatif temsillerin geliştirilmesini gerekli kılmaktadır. Nitekim sabit ızgara yapısına sahip voksel temsilleri, geniş boş veya bilgi içermeyen bölgeleri dahi işlemeye zorladığından hesaplama maliyetini kaçınılmaz olarak artırmaktadır.

Bu tez çalışmasında, böbrek ve pankreas segmentasyonu problemleri, nokta bulutu tabanlı ve voksel tabanlı yöntemler kullanılarak farklı veri setleri üzerinde kapsamlı bir şekilde ele alınmıştır. Böbrek segmentasyonunda, düşük hesaplama

maliyetli yama (patch) tabanlı yöntemler ayrıntılı biçimde incelenmiştir. Doğruluk ve hesaplama verimliliği arasındaki dengeyi optimize etmek amacıyla, iki aşamalı bir kaba–ince segmentasyon çerçevesi tasarlanmıştır. İlk aşamada düşük çözünürlüklü hacimler üzerinden kaba lokalizasyon gerçekleştirilmiş, ikinci aşamada ise yüksek çözünürlüklü ilgi alanları (İA’lar) üzerinde ayrıntılı (ince) segmentasyon yapılmıştır. Bu kapsamda U-Net, Dikkat Mekanizmalı U-Net (AttUNet), Artık Öğrenme Tabanlı U-Net (ResUNet), Çok Ölçekli Özellik Birleşimi ve Dikkat Mekanizmalı U-Net (MFFAU-Net) ve Dönüştürücü Tabanlı U-Net (TransUNet) mimarileri değerlendirilmiş; KiTS19, Kits23 ve FLARE22 veri setleri üzerinde kapsamlı eğitim ve test deneyleri yürütülmüştür. Benzer şekilde, pankreas segmentasyonu için de ResUNet ve TransUNet mimarileri MSD Task_07 Pankreas ve FLARE22 veri setleri üzerinde uygulanmış ve böbrek segmentasyonu ile karşılaştırmalı bir analiz gerçekleştirilmiştir. Elde edilen sonuçlar, voksel tabanlı yaklaşımların organ segmentasyonunda yüksek doğruluk sunduğunu; ancak hesaplama maliyetleri, alan kaymasına karşı duyarlılık, veri çeşitliliği ve genelleme kabiliyeti gibi temel zorlukların halen devam ettiğini ortaya koymuştur.

Voksel tabanlı yöntemlerin sınırlılıklarına yanıt olarak, bu tezde aynı zamanda nokta bulutu tabanlı derin öğrenme yaklaşımları da incelenmiştir. Nokta bulutları, üç boyutlu organları doğrudan $[x, y, z]$ koordinatları ile gri seviye (yoğunluk) bilgisi üzerinden temsil ederek verinin boyutunu önemli ölçüde azaltmakta; böylece daha hafif, bellek dostu ve esnek bir işlem altyapısı sunmaktadır. Bu kapsamda farklı örnekleme stratejileri uygulanmış, çeşitli nokta sayılarında ve eksik örnekleme (under-sampling) koşullarında modellerin dayanıklılığı sistematik olarak değerlendirilmiştir. Bilgisayarla görü alanında PointNet ve Dinamik Grafik Konvolüsyonel Sinir Ağı (Dynamic Graph Convolutional Neural Network, DGKSA) gibi modeller, nesne tanıma ve segmentasyon görevlerinde yüksek başarı sağlamış; ancak bu modellerin tıbbi görüntü segmentasyonu problemine uygulanmasının henüz sınırlı düzeyde olduğu tespit edilmiştir. Bu doğrultuda, yalnızca anlamlı anatomik noktaları işleme yeteneği sayesinde nokta bulutu temsillerinin, tıbbi görüntü segmentasyonunda daha esnek, hafif ve hesaplama açısından verimli bir alternatif oluşturduğu ortaya konmuştur.

Belirgin anatomik sınırları, simetrik yapısı ve çevre dokularla arasındaki kontrast farkı sayesinde, böbrek segmentasyonu nokta bulutu tabanlı yaklaşımların uygulanması için uygun bir başlangıç noktası oluşturmaktadır. Buna karşılık pankreas, yüksek morfolojik değişkenlik, komşu organlarla yoğunluk benzerliği ve göreceli olarak küçük hacmi nedeniyle, üç boyutlu uzamsal temsilin en karmaşık örneklerinden birini

sunmaktadır. Dolayısıyla bu iki organ üzerinden yürütülen karşılaştırmalı analiz, derin öğrenme modellerinin anatomik karmaşıklık ve veri temsil zorluklarına karşı gösterdiği adaptasyon kapasitesini değerlendirmek açısından özgün bir araştırma zemini yaratmaktadır. Böylelikle çalışma, yalnızca böbrek ve pankreas özelinde değil, genel olarak nokta bulutu temsiline dayalı tıbbi görüntü segmentasyonunda organ-spesifik faktörlerin model performansı üzerindeki etkilerini ortaya koyarak alana yeni bir bakış açısı kazandırmaktadır.

Sonuç olarak, bu tez çalışması, tıbbi görüntü segmentasyonunda hem voksel tabanlı hem de nokta bulutu tabanlı (PointNet, DGKSA) derin öğrenme yaklaşımlarını bütüncül bir çerçevede bir araya getiren, çok aşamalı kaba–ince segmentasyon stratejisine dayalı yenilikçi bir metodolojik yaklaşım ortaya koymaktadır. Nokta bulutu temsili, her bir noktanın $[x, y, z]$ koordinatları üzerinden doğrudan mesafe ve geometrik ilişki bilgisini koruması, verinin boyutunu önemli ölçüde azaltması ve bellek dostu bir işlem altyapısı sunması sayesinde, derin ağların uzamsal farkındalığını güçlendirmekte ve organ yüzeylerinin topolojik özelliklerinin daha hassas biçimde öğrenilmesine olanak tanımaktadır. Çalışmanın temel hedefi, böbrek ve pankreas segmentasyonu gibi farklı morfolojik karmaşıklığa sahip organlar üzerinden, veri temsiline bağlı performans farklılıklarını nicel ve nitel olarak sistematik biçimde incelemek ve bu analizler aracılığıyla derin öğrenme modellerinin organ-spesifik zorluklara karşı genelleme kapasitesini ve uzamsal adaptasyon yeteneğini değerlendirmektir. Elde edilen bulgular, yalnızca ilgili organların segmentasyonuna yönelik pratik çıkarımlar sunmakla kalmayıp, aynı zamanda nokta bulutu temelli tıbbi görüntüleme yaklaşımlarına metodolojik bir referans çerçevesi kazandırarak gelecekteki araştırmalara yön verici bir katkı sağlamaktadır.

2. KAYNAK ARAŞTIRMASI

Bu bölümde, tıbbi görüntüleme alanında abdomen, böbrek ve pankreas segmentasyonu üzerine gerçekleştirilen literatür çalışmaları ile nokta bulutu tabanlı derin öğrenme yaklaşımlarına ilişkin araştırmalar incelenmiştir. Literatürde, BT ve dinamik BT verileri üzerinde gerçekleştirilen organ segmentasyon çalışmalarının büyük çoğunluğu voksel tabanlı derin öğrenme yöntemlerine dayanmaktadır. Bu yöntemler 3B hacimsel bilgiyi doğrudan işleyebilse de artan veri boyutlarında hesaplama süresi ve bellek kullanımı hızla yükseldiğinden, büyük ölçekli veri setlerinde verimli bir şekilde çalışılması güçleşmektedir.

Bu tez kapsamında, BT görüntülerinde böbrek ve pankreas segmentasyonunu gerçekleştirmek amacıyla çok aşamalı, derin öğrenme tabanlı bir sistem tasarlanmıştır. Çalışmada ayrıca, kaba segmentasyon sürecine zemin oluşturmak amacıyla abdomen segmentasyonuna yönelik ön hazırlık niteliğinde bir araştırma da gerçekleştirilmiş; ancak bu aşama önerilen sistemin doğrudan bir bileşeni olarak değerlendirilmemiştir. Önerilen çalışmada, böbrek ve pankreas organları için kaba ve ince segmentasyon işlemleri birbirinden bağımsız olarak yürütülmüştür. Bu doğrultuda çalışma;

- (1) böbrek için kaba segmentasyon,
- (2) böbrek için ince segmentasyon,
- (3) nokta bulutu tabanlı ince böbrek segmentasyonu ve
- (4) pankreas için kaba ve ince segmentasyonun birlikte değerlendirildiği nokta bulutu–voksel tabanlı analiz olmak üzere dört farklı uygulamayı içermektedir.

Literatürde böbrek ve pankreas segmentasyonu üzerine çok sayıda çalışma bulunmasına rağmen, mevcut araştırmaların büyük kısmı yalnızca voksel tabanlı temsillere odaklanmıştır. Oysa nokta bulutu tabanlı derin öğrenme yaklaşımları, doğrudan $[x, y, z]$ koordinatları üzerinden geometrik ve mesafe bilgilerini koruyarak verinin 3B yapısını daha verimli biçimde temsil edebilmekte ve modelin uzamsal farkındalığını artırabilmektedir. Ancak bu potansiyel, tıbbi görüntü segmentasyonu bağlamında henüz yeterince araştırılmamış ve kullanılmamıştır.

Bu bağlamda hem böbrek hem de pankreas organları üzerinde nokta bulutu ve voksel tabanlı yöntemlerin sistematik biçimde karşılaştırıldığı bu çalışma, yöntemsel çeşitliliği, çok aşamalı tasarımı ve farklı organların anatomik özelliklerine karşı derin öğrenme modellerinin genelleme ve uyum kapasitesine ilişkin kapsamlı değerlendirmeleriyle literatüre özgün bir katkı sunmaktadır.

Bu bölümde, söz konusu çok aşamalı sistemin temelini oluşturan araştırma alanlarına ilişkin literatür çalışmaları sunulmaktadır. İlk olarak abdomen segmentasyonuna yönelik yaklaşımlar incelenmiş, ardından böbrek ve pankreas segmentasyonunda kullanılan güncel derin öğrenme yöntemleri ele alınmıştır. Son olarak, 3B tıbbi verilerin alternatif bir temsil biçimi olan nokta bulutu tabanlı yaklaşımlar ve bu yaklaşımların tıbbi görüntü analizine uygulanabilirliği değerlendirilmektedir.

2.1. Abdomen Segmentasyonu Üzerine Literatür Çalışmaları

BT görüntüleri, abdomen bölgesini kapsayan geniş veri alanlarıyla birlikte tıbbi görüntü işleme çalışmalarında en yaygın kullanılan görüntüleme yöntemlerinden biridir. Ancak bu görüntülerde, klinik açıdan bilgi içermeyen geniş siyah arka plan bölgelerinin bulunması önemli bir sınırlılık oluşturmaktadır. Bu nedenle, ilgi alanlarının (İA'ların) doğru biçimde belirlenmesi, arka plan piksellerinin elimine edilmesini ve modelin yalnızca anlamlı anatomik bölgelere odaklanmasını sağlayan kritik bir ön işleme adıdır. Bu bölümde sunulan çalışmalar, doğrudan abdomen segmentasyonu veya İA tespiti amacıyla geliştirilen yöntemlerle ilişkilidir.

Koyuncu ve ark. (2018), AbSeg adını verdikleri ve morfolojik işlemler ile mekânsal bulanık C-ortalamar kümeleme yöntemini de içeren sekiz aşamalı bir algoritma önermiştir. Ancak, çalışma yalnızca 58 BT görüntüsü üzerinde gerçekleştirilmiş ve segmentasyon 2B düzlemle sınırlı kalmıştır.

Son yıllarda, kendi kendine denetimli (self-supervised) ön eğitim yöntemleri, etiketlenmemiş verilerin tıbbi görüntüleme alanında kullanılmasına imkân tanımaktadır. Bununla birlikte, doğru segmentasyon için gerekli olan alan-özellik özellikler sebebiyle bu yöntemlerin etkinliği sınırlı olabilmektedir (Reed ve ark., 2022). Doğal görüntüler üzerinde eğitilmiş modeller, ince anatomik farklılıkları yakalamakta yetersiz kalmakta ve sonuç olarak optimal performans elde edilememektedir (Chen ve ark., 2019). Örneğin, Faster R-CNN gibi önceden eğitilmiş modeller umut verici sonuçlar üretse de yapılan çalışmalar kendi kendine denetimli ön eğitim yöntemlerinin doğruluk açısından denetimli yaklaşımları geride bırakmadığını göstermektedir (Larsson ve ark., 2017). Ayrıca bu yöntemler yüksek hesaplama maliyetleri doğurmaktadır. Nitekim Wolf ve ark. (2023) tarafından yapılan çalışmada, her biri yaklaşık 30 gün süren dört ayrı ön eğitim süreci yürütülmüş ve performans değerlendirmesi için 400'ün üzerinde ince ayar işlemi gerçekleştirilmiştir. Dolayısıyla, mevcut çalışmalar tıbbi görüntülerdeki karmaşık

anatomik yapılar için hem yüksek doğruluk hem de hesaplama açısından verimli çözümler sunmakta yetersiz kalmakta; bu durum, daha dengeli ve hedefe yönelik ön işleme stratejilerinin gerekliliğini ortaya koymaktadır.

Son yıllarda, İA tespitinde denetimli derin öğrenme mimarilerinden de yararlanılmaktadır. Bazı ağ yapıları, İA kırpma işlemini doğrudan ağ mimarisi içerisine entegre etmektedir (Girshick ve ark., 2013; He ve ark., 2017). Bu tür yaklaşımlarda genellikle nesne tespiti yöntemleri kullanılmakta, ilk olarak İA belirlenmekte ve ardından segmentasyon sürecine dahil edilmektedir. He ve ark. (2017) tarafından önerilen Mask R-CNN modeli, İA çıkarımını özellik maskeleri üzerinden gerçekleştirerek bu yaklaşımı daha ileri taşımaktadır. Ancak, bu yöntemlerde giriş görüntülerinin indirgenmiş (aşağı ölçeklenmiş) biçimde ağa verilmesi, ince detayların kaybolmasına yol açmaktadır (Jha ve ark., 2021). Buna karşın, bu tez kapsamında geliştirilen yaklaşımda, kullanılmayan piksellerin kırılmasıyla daha küçük ve bilgi yoğun giriş görüntüleri elde edilmekte ve bu işlem, ağdan bağımsız bir ön işleme adımı olarak uygulanmaktadır. Zhou ve ark. (2017) sabit-nokta modeli ile pankreas İA'sını belirlemiş, Tran ve ark. (2022) ise mamografi görüntülerinde İA tespiti için YOLOv5 algoritmasını kullanmıştır. Ancak bu çalışmalar yalnızca 2B görüntülere odaklanmıştır.

Karaciğer ve lezyon segmentasyonu, beyin tümörü segmentasyonu ve pankreas segmentasyonu gibi uygulamalarda, kaba–ince (coarse-to-fine) yaklaşıma dayalı ardışık (cascaded) ağların yaygın olarak kullanıldığı görülmektedir (Albishi ve ark., 2019; Christ ve ark., 2016; Jha ve ark., 2021; Li ve ark., 2020; Wang ve ark., 2018). Bu ağlar genellikle iki aşamalı olup, ilk ağ İA tespitine dayalı kaba segmentasyonu, ikinci ağ ise ince segmentasyonu gerçekleştirmektedir. Ancak bu tür yapılar, parametre sayısı ve bellek gereksinimi açısından tek bir ağın yaklaşık iki katına ihtiyaç duymakta, bu da klinik uygulamalar açısından donanım sınırlılıkları doğurmaktadır (Zhao ve ark., 2022). Bu çalışmada ise, Grafik İşlem Birimi (Graphics Processing Unit, GPU) bellek kullanımını en aza indirmek amacıyla bağımsız bir ön işleme adımı önerilmektedir.

Benčević ve ark. (2023) tıbbi görüntü segmentasyonunu iki aşamada gerçekleştirmiştir. İlk aşamada giriş görüntüleri düşük çözünürlüğe aşağı ölçeklenmiş, ardından İA'lar orijinal görüntüden çıkarılmıştır. İkinci aşamada ise bu bölgeler, 2B U-Net tabanlı bir ağ kullanılarak ince segmentasyona tabi tutulmuştur. Çalışmaları yöntemsel açıdan benzerlik gösterse de bu tez kapsamında önerilen yaklaşım, 3B tıbbi görüntüler için özel olarak tasarlanmış 3B U-Net tabanlı bir ön işleme adımı içermesi bakımından literatürde farklılaşmaktadır.

Özetle, BT görüntülerinde İA çıkarımı ve abdomen segmentasyonu üzerine birçok çalışma yapılmış olsa da bu çalışmaların her birinde çeşitli sınırlılıklar bulunmaktadır. Bu sınırlılıklar arasında 2B görüntülere bağımlılık, yüksek hesaplama maliyetleri ya da önceden eğitilmiş modellerin optimal olmayan kullanımı sayılabilir. Önerilen 3B U-Net tabanlı ön işleme yöntemimiz ise mevcut tekniklerdeki temel eksiklikleri gidermesi bakımından farklılaşmaktadır. Daha önceki yaklaşımların aksine, yöntemimiz giriş veri boyutunu etkin biçimde küçültmekte, hesaplama yükünü azaltmakta ve kritik anatomik özelliklerin korunmasını sağlamaktadır. Ayrıca, kırpma yoluyla gerçekleştirilen doğru İA çıkarımı sayesinde abdomen bölgesindeki ince detayların kaybı önlenmekte, böylece tıbbi görüntü segmentasyonu için sağlam ve verimli bir ön işleme çözümü sunulmaktadır.

Bu tez kapsamında yürütülen ön araştırma, BT görüntülerinde bilgi içermeyen arka plan piksellerini ortadan kaldırmaya yönelik abdomen segmentasyonunu ele almaktadır. Önerilen yaklaşımda, 3B U-Net tabanlı derin öğrenme modelleri kullanılarak segmentasyon gerçekleştirilmiş; tespit için alt ölçekleme (downscaling) uygulanmış ve ardından orijinal görüntülerden kırpma işlemi yapılmıştır. Bu sayede, görüntüdeki kritik bölgelerin bilgi içeriği korunmuş, ince detaylar kaybolmamıştır. Sunulan yöntem, abdomen segmentasyonu çalışmalarında genel bir ön işleme adımı olarak kullanılabilecek nitelikte olup, tıbbi görüntü analizinde doğruluk ve verimliliği artırmaya yönelik umut vadeden bir çözüm sunmaktadır.

2.2. Böbrek Segmentasyonu Üzerine Literatür Çalışmaları

Derin öğrenme tabanlı mimariler, böbrek segmentasyonunda son yıllarda kayda değer ilerlemeler sağlamış olsa da bu alanda halen iki temel güçlük öne çıkmaktadır. İlk olarak, böbreğin BT görüntülerinde görece küçük bir alan kaplaması, ikincisi ise 3B tıbbi görüntülerin yüksek boyutlu olmasıdır. 3B verilerin doğrudan ağlara aktarılması genellikle aşağı ölçekleme ile gerçekleştirilmektedir; ancak bu yaklaşım, böbrek kenarlarında ve ince anatomik yapılarda bilgi kaybına neden olabilmektedir (Jha ve ark., 2021). Bu nedenle literatürde yaygın olarak benimsenen yaklaşım, önce kaba segmentasyonla böbreğe ait ilgi alanlarının belirlenmesi, ardından bu bölgelerin ince segmentasyonla daha ayrıntılı biçimde işlenmesidir. Böylelikle hem hesaplama yükü azaltılmakta hem de GPU bellek kullanımı optimize edilmektedir.

Fatemeh ve ark. (2020), 315 veriye ait Kontrastlı Bilgisayarlı Tomografi (KBT) verilerini kullanarak böbrek segmentasyonu için 3B U-Net tabanlı bir yöntem önermiştir.

Kits19 veri setinden seçilen 60 test örneğinde ortalama %96,25 Dice Benzerlik Katsayısı (DBK) elde edilmiştir. Ancak, ağı 4:4:2 oranında aşağı ölçekleme (subsampling) ile eğitilmesi, böbrek sınırlarında bilgi kaybına yol açmıştır.

Lin ve ark. (2021) ise kaba ve ince segmentasyonu içeren iki aşamalı bir 3B U-Net yaklaşımı geliştirmiştir. İlk aşamada görüntü enine düzlemde bölünerek sağ ve sol böbrekler ayrıştırılmış, ardından görüntü boyutu 64×64 'e indirgenmiş ve böbreklerin lokalizasyonu için ağ eğitilmiştir. Modelin çıktıları doğrultusunda orijinal görüntülerden $128 \times 128 \times 128$ boyutlarında İA'lar kırılmış ve bunlar ince segmentasyon için ikinci bir ağa aktarılmıştır. Bu çalışma yöntemsel açıdan bizim yaklaşımımıza yakın olmakla birlikte iki önemli farklılık barındırmaktadır: (i) Lin ve ark. (2021) toplamda dört ağ (iki kaba ve iki ince segmentasyon için) kullanırken, bizim yaklaşımımız yalnızca üç ağ (bir kaba ve iki ince segmentasyon için) gerektirmektedir. (ii) Onların yönteminde böbrek İA'ları sabit boyutlu pencereler ($128 \times 128 \times 128$) olarak tanımlanmış, oysa bizim yöntemimizde İA boyutu dinamik olarak belirlenmiş ve her bir verinin yapısal özelliklerine uyarlanmıştır. Böylece, sabit pencere yaklaşımının yüksek kesit sayısına sahip BT görüntülerinde yol açabileceği bilgi kaybı önlenmiştir.

Pandey ve ark. (2022), böbrek segmentasyonu için 3B U-Net tabanlı bir ağ önermiş ve İA belirleme sürecinde omurga merkezini referans almıştır. Bunun için önce omurga kemiğinin konumu uyarlamalı eşikleme (adaptive thresholding) ile tespit edilmiş, ardından aktif kontur yöntemiyle (active contour method) omurga merkezi belirlenmiştir. Bu referans noktadan hareketle sağ ve sol böbrek İA'ları 128×128 piksel pencereler olarak çıkarılmıştır. Ancak, çalışmada böbreklerin her zaman yan yana konumlandığı varsayılmış, bireysel anatomik farklılıklar dikkate alınmamıştır. Ayrıca görüntülerin z-ekseninde sabit sayıda 128 kesite ayrılması, böbrek boyutu ve pozisyonundaki değişiklikleri göz ardı etmiş ve segmentasyon doğruluğunu sınırlamıştır. Çalışmamız ise bu noktada önemli bir farklılık sunmaktadır: Sabit İA pencereleri yerine dinamik İA tanımlaması yapılarak, veriye özgü anatomik farklılıklar dikkate alınmış ve böylece modelin genellenebilirliği ile güvenilirliği artırılmıştır.

Bu tez kapsamında iki ayrı derin öğrenme tabanlı böbrek segmentasyon çalışması yürütülmüştür. İlk çalışmada, kaba segmentasyon aşamasında 3B U-Net kullanılarak her veriye özgü sağ ve sol böbrek İA'ları belirlenmiştir. Ardından, her iki böbreğe ait İA'lar veri yapısına göre çıkarılmış ve ince segmentasyon aşamasında bağımsız olarak işlenmiştir. Bu süreçte üç mimari incelenmiştir: hacimsel veriyi veksle düzleminde işleyen 3B U-Net ile nokta bulutu temelli iki ağ mimarisi olan PointNet ve DGKSA.

Böylelikle, literatürde baskın olan yalnızca voksel tabanlı yaklaşımların ötesine geçilerek nokta bulutu temsillerinin böbrek segmentasyonundaki potansiyeli sistematik biçimde ortaya konulmuştur. Tüm modeller KiTS23 veri seti üzerinde eğitilmiş ve FLARE22 veri seti üzerinde test edilmiştir. Böylece, veri kümesine özgü bağımlılıklar dışında, modellerin gerçek anlamda genelleme kapasitesi değerlendirilmiştir.

İkinci çalışmada, segmentasyon performansının kapsamlı bir şekilde değerlendirilmesi amacıyla çok aşamalı ve yama (patch) tabanlı bir çerçeve geliştirilmiştir. Kaba segmentasyon aşamasında yama tabanlı U-Net, AttUNet ve ResUNet olmak üzere üç farklı mimari kullanılmıştır. Bu modeller, sırasıyla simetrik kodlayıcı–kod çözücü yapısı, dikkat kapıları ve artık bağlantılar aracılığıyla uzamsal kodlama, bölgesel odaklanma ve derin özellik çıkarımı açısından farklı avantajlar sunmaktadır. İnce segmentasyon aşamasında ise MFFAU-Net ve TransUNet gibi ileri düzey mimariler değerlendirilmiştir. MFFAU-Net, çok ölçekli özellik birleştirme ve dikkat mekanizmalarını entegre ederek sınır hassasiyetini artırırken; TransUNet, konvolüsyonel katmanlar ile dönüştürücü tabanlı öz-dikkat (self-attention) modüllerini birleştirerek uzun menzilli bağlamsal ilişkileri etkili bir biçimde yakalamaktadır. Bu yama tabanlı çok aşamalı yaklaşım, bellek verimliliğini korurken aynı zamanda anatomik olarak karmaşık bölgelerde segmentasyon doğruluğunu artırmayı hedeflemiştir.

2.3. Pankreas Segmentasyonu Üzerine Literatür Çalışmaları

Abdominal organ segmentasyonu genel olarak iki ana kategoriye ayrılmaktadır: model tabanlı ve öğrenme tabanlı yaklaşımlar (Ma ve ark., 2021). Model tabanlı yöntemler arasında atlas kaydı, istatistiksel şekil modelleri ve enerji fonksiyonu minimizasyon algoritmaları yer almaktadır (Moglia ve ark., 2024). Bu yöntemler, eğitim verilerinden elde edilen anatomik varyasyonları yakalayarak yeni görüntülere uyarlamayı amaçlamaktadır (Gibson ve ark., 2018). Ancak, özellikle sınırları belirsiz ve karışıklığı düşük olan pankreas gibi organlarda bu yöntemlerin performansı sınırlı kalmaktadır (Ma ve ark., 2021). Pankreas segmentasyonunda karşılaşılan temel zorluklar; organın küçük ve düzensiz yapısı, yüksek anatomik değişkenlik göstermesi ve on iki parmak bağırsağı ile safra kesesi gibi komşu organlarla olan yakın mekânsal ilişkileridir (Yan ve Zhang, 2021).

Bu sınırlılıkların üstesinden gelmek amacıyla öğrenme tabanlı yaklaşımlar geliştirilmiştir. Bu yöntemlerde segmentasyon, etiketlenmiş BT görüntülerinden anlamlı

özelliklerin doğrudan öğrenilmesiyle gerçekleştirilmektedir (Ma ve ark., 2021). Etiketleme durumuna göre öğrenme tabanlı yöntemler; denetimli, yarı denetimli ve denetimsiz olarak sınıflandırılabilir (Engelen ve Hoos, 2020). Son yıllarda yapılan çalışmalar, derin öğrenme tabanlı segmentasyon ağlarının, yoğunluk tabanlı eşikleme, morfolojik işlemler ve geometrik analiz gibi geleneksel yöntemlere kıyasla medikal görüntü segmentasyonunda daha üstün performans gösterdiğini ortaya koymuştur (Fu ve ark., 2021; Lim ve ark., 2022). Derin öğrenmede yaşanan gelişmelerle birlikte KSA'lar sınıflandırma, tespit ve segmentasyon gibi pek çok tıbbi görüntüleme görevinde etkin öğrenme tabanlı yöntemler olarak öne çıkmıştır. Segmentasyon uygulamalarında KSA tabanlı yöntemler genellikle 2B, 2.5B, yama tabanlı 3B ve 3B modeller olarak dörde ayrılmaktadır.

2B modeller, BT hacimlerini kesit düzeyinde (aksiyal, sagittal veya koronal) dilimleyerek her bir kesiti ağ girişine sunmaktadır (Yue Zhang ve ark., 2021). Bu ağlardan yalnızca aksiyal düzlem kesitleriyle eğitilenler de mevcuttur (Kurnaz ve ark., 2024). Her ne kadar bu yaklaşımlar hesaplama açısından oldukça verimli olsa da kesitler arası bağlamsal ilişkileri tam olarak modelleyememe eğilimindedir (Wang ve ark., 2021). Öte yandan, 3B modeller hacimsel veriyi doğrudan işleyerek daha zengin mekânsal bağlam sağlamaktadır. Ancak bu yöntemlerin yüksek hesaplama maliyeti ve büyük miktarda etiketli veriye duyduğu ihtiyaç, klinik uygulamalardaki en önemli kısıtlardır (Yan ve Zhang, 2021). Bu iki uç arasında bir denge kurmak amacıyla geliştirilen yama tabanlı yaklaşımlar hem 3B bağlamsal bilgiyi yakalamayı hem de bellek kullanımını azaltmayı hedeflemektedir (Asadpour ve ark., 2021).

Her ne kadar 3B ağlar hacimsel özelliklerin öğrenilmesinde güçlü performans sergilese de yüksek hesaplama yükü ve geniş etiketli veri gereksinimi klinik kullanım açısından önemli sınırlılıklar doğurmaktadır. Buna karşılık, 2B modeller üç anatomik düzlemde ayrı ayrı işlenen görüntü çıktılarının birleştirilmesiyle hacimsel segmentasyon elde etmeye çalışmaktadır. Ancak pankreas gibi küçük, düzensiz ve sınırları belirsiz organlarda bu yöntemler arka plan etkilerinden olumsuz yönde etkilenebilmektedir (Zhang ve ark., 2021).

Derin öğrenme tabanlı pankreas segmentasyonu yaklaşımları genel olarak iki gruba ayrılmaktadır: doğrudan yöntemler ve iki aşamalı yöntemler (Y. Chen ve ark., 2022). Doğrudan yöntemlerde segmentasyon, tek adımda doğrudan görüntü üzerinde gerçekleştirilmektedir. İki aşamalı yöntemlerde ise önce pankreasın kaba bir lokalizasyonu yapılmakta, ardından belirlenen bölge içerisinde daha hassas bir modelle

ince segmentasyon uygulanmaktadır (Qureshi ve ark., 2022). Bu tür çok aşamalı yöntemler, pankreasın çevre dokularla benzer yoğunluk ve yapısal özellikler göstermesi nedeniyle sınırlarının daha doğru belirlenmesini sağlamanın yanı sıra hesaplama yükünü de azaltmaktadır.

Literatürde bu zorluğun üstesinden gelmek için çeşitli iki aşamalı stratejiler önerilmiştir. Örneğin Roth ve ark. (2018), çok organlı abdominal segmentasyon için iki aşamalı bir 3B U-Net modeli geliştirmiştir. İlk aşamada kaba lokalizasyon yapılmış, ardından ikinci aşamada detaylı segmentasyon gerçekleştirilmiş ve pankreas için %82,2 DBK elde edilmiştir. Ancak hem kaba hem de ince segmentasyonun aynı ağ mimarisi içinde yürütülmesi, geleneksel yöntemlere kıyasla yaklaşık iki kat daha fazla bellek kullanımına yol açmıştır (Zhao ve ark., 2022). Benzer şekilde Yang ve ark. (2019), hem kesit içi hem de kesitler arası bilgileri kullanan ardışık (cascade, kaskat) bir sinir ağı önermiştir. Bu yaklaşımda, kesit içi özelliklerin çıkarımı için Tam Evrişimsel Ağ (Fully Convolutional Network, TEA), kesitler arası ilişkilerin modellenmesi için ise Tekrarlayan Sinir Ağı (Recurrent Neural Network, TSA) kullanılmıştır. Liu ve ark. (2020), kaba segmentasyon aşamasında aday pankreas bölgelerini süperpiksel tabanlı yama sınıflandırması ile belirlemiş, ardından farklı kayıp fonksiyonlarıyla eğitilmiş beş ayrı 2.5B U-Net kullanmış ve çıktıları bir topluluk (ensemble) modeli ile birleştirerek nihai sonuçları elde etmiştir. Bir başka çalışmada Hu ve ark. (2020), kaba segmentasyon için çoklu-atlas kaydını, ince segmentasyon için ise yama tabanlı 3B KSA ile üç adet 2B KSA'yı entegre etmiştir. 3B KSA tarafından üretilen olasılık haritaları pankreas için bir sınırlayıcı kutu (bounding box) tanımlamak amacıyla kullanılmış, bu kutu orijinal BT görüntüsüyle birleştirilerek üç ardışık 2B U-Net'e aktarılmıştır. Son aşamada ise, organ sınırlarının daha hassas biçimde belirlenebilmesi amacıyla 3B seviye küme yöntemi (3D Level Set method) uygulanmıştır.

Bu tez kapsamında, iki farklı veri seti kullanılarak yama tabanlı iki aşamalı bir segmentasyon yaklaşımı önerilmektedir. Önerilen çerçeve, kaba ve ince segmentasyon olmak üzere iki aşamadan oluşmaktadır. Kaba segmentasyon aşamasında ResUNet mimarisi; ince segmentasyon aşamasında ise U-Net, ResUNet ve TransUNet olmak üzere üç farklı derin öğrenme mimarisi değerlendirilmiştir. Kaba segmentasyon aşamasında iki ayrı çalışma yürütülmüştür. İlk çalışmada, MSD Task07 Pankreas veri setinden seçilen 240 örnek kullanılarak 3B ResUNet modeli eğitilmiştir. İkinci çalışmada ise, modelin genelleme kapasitesini artırmak ve farklı veri kaynaklarına uyum yeteneğini incelemek

amacıyla aynı 240 MSD örneğine ek olarak FLARE22 veri setinden 10 örnek daha eğitime dahil edilmiştir.

Önerilen yöntemin etkinliğini kapsamlı biçimde değerlendirmek amacıyla yalnızca nicel metrikler değil, aynı zamanda nitel analizler de gerçekleştirilmiştir. Bu doğrultuda, veri setinde en yüksek ve en düşük başarı gösteren örneklerin segmentasyon sonuçları karşılaştırmalı olarak sunulmuş, böylece modelin güçlü ve zayıf yönleri görsel açıdan ortaya konmuştur.

Ayrıca, bu tezde nokta bulutu tabanlı yöntemlerden PointNet ve DGKSA kullanılmıştır. Literatür incelemesi sonucunda, nokta bulutu tabanlı pankreas segmentasyonu üzerine herhangi bir çalışmaya rastlanmamış olması, önerilen yaklaşımın yenilikçi yönünü ve bilimsel katkısını açıkça ortaya koymaktadır. Bunun yanında, önerilen yöntem böbrek segmentasyonu için de uygulanmış ve her iki organ üzerinde nokta bulutu tabanlı ve voksel tabanlı yöntemlerin karşılaştırmalı analizi yapılmıştır.

2.4. Nokta Bulutu Uygulamaları Üzerine Literatür Çalışmaları

Üç boyutlu tıbbi görüntülerde organ segmentasyonu, anatomik yapıların doğru biçimde ayrıştırılması ve hacimsel analizin güvenilir biçimde yapılabilmesi açısından büyük önem taşımaktadır. Geleneksel olarak bu amaçla kullanılan voksel tabanlı yöntemler (örneğin 3B U-Net türevleri), yüksek doğruluk oranları sunmalarına rağmen yoğun bellek gereksinimi ve yüksek hesaplama maliyeti gibi dezavantajlara sahiptir. Bu nedenle son yıllarda, nokta bulutu (point cloud) tabanlı yaklaşımlar tıbbi görüntü segmentasyonunda alternatif bir çözüm olarak öne çıkmaktadır. Nokta bulutu tabanlı yöntemler, doğrudan üç boyutlu uzayda tanımlanmış nokta kümeleri üzerinde çalıştıkları için, veri temsilde seyrek (sparse) ve hafif (lightweight) bir yapı sunarak hem bellek verimliliğini artırmakta hem de daha esnek bir geometri öğrenimi sağlamaktadır.

Bu tür yaklaşımlar genellikle her bir noktayı bağımsız olarak modellemek için Çok Katmanlı Algılayıcılar (Multi-Layer Perceptrons, ÇKA'lar) kullanır. Noktalardan çıkarılan öznitelikler, dönüşüm değişmezliğini korumak amacıyla simetrik toplama işlevleri (örneğin maksimum havuzlama) ile birleştirilerek küresel bir özellik vektörü oluşturulur. Bununla birlikte, bu tür simetrik işlemler tüm nokta grubundaki yerel geometrik ilişkilerin ve uzamsal korelasyonların yeterince yakalanmasına engel olabilmektedir (Matrone ve ark., 2020).

Bu alandaki öncü çalışmalardan biri olan PointNet (Qi ve ark. (2017a)) nokta bulutu verisini doğrudan işleyen ilk derin öğrenme mimarilerinden biri olarak kabul edilmektedir. PointNet, her noktayı bağımsız olarak işleyip elde edilen öznitelikleri simetrik bir fonksiyonla birleştirerek, dönüşüm değişmezliğini garanti altına alır. Ancak bu yapı, nokta bulutu üzerindeki yerel geometrik ilişkileri doğrudan modelleyemediğinden, özellikle ince ve düzensiz anatomik yapılar (örneğin pankreas dokusu) gibi karmaşık bölgelerde sınırlı performans sergileyebilmektedir.

Bu eksiklikleri gidermek amacıyla Qi ve ark. (2017b) tarafından geliştirilen PointNet++, çok ölçekli örnekleme ve hiyerarşik özellik toplama katmanları ekleyerek, yerel ve küresel bilgilerin birlikte öğrenilmesini sağlamıştır. Böylece, farklı yoğunlukta örneklenmiş nokta kümeleri üzerinden çok ölçekli bağlamsal özellik çıkarımı mümkün hale gelmiştir.

Yerel ilişkilerin daha etkili biçimde modellenebilmesi için Wang ve ark. (2019) tarafından önerilen DGKSA nokta bulutu verisini dinamik bir grafik yapısına dönüştürerek, her bir iterasyonda noktalar arasındaki komşuluk ilişkilerini yeniden belirler. Bu sayede, ağ hem topolojik hem de geometrik ilişkileri dinamik biçimde öğrenebilir. DGKSA'nın bu özelliği, özellikle organ sınırlarının belirsiz olduğu medikal görüntülerde (örneğin pankreas ve böbrek çevresi dokularında) segmentasyon başarımını artırmaktadır.

Son dönemde, Sun ve ark (2023) tarafından önerilen Superpoint Transformer, Qi ve ark. (2024) tarafından önerilen Recon++, Mohammadi ve ark. (2021) tarafından önerilen PointView-GCN ve Han ve ark. (2024) tarafından önerilen Mamba3D + Point-MAE gibi gelişmiş modeller, nokta bulutu verisinden bağlamsal ve semantik bilgiyi daha etkili biçimde çıkararak segmentasyon doğruluğunu artırmıştır. Bu modeller, dönüştürücü tabanlı dikkat mekanizmaları sayesinde hem yerel hem de küresel düzeydeki ilişkileri aynı anda değerlendirebilmekte, böylece nokta bulutu içindeki ince yapısal ayrıntıları daha iyi yakalayabilmektedir. Bununla birlikte, bu gelişmiş yöntemlerin artan parametre sayıları ve karmaşık hesaplama yapıları, yüksek bellek kullanımı ve uzun eğitim süreleri gibi önemli dezavantajları da beraberinde getirmektedir. Bu nedenle, hafif yapıli modeller (örneğin PointNet ve DGKSA) halen birçok klinik veya araştırma ortamında uygulanabilirliğini korumaktadır.

Bu çalışma kapsamında, pankreas ve böbrek segmentasyonu için nokta bulutu tabanlı iki farklı yaklaşım incelenmiştir: PointNet ve DGKSA. PointNet, düşük parametre sayısı ve yüksek işlem verimliliği sayesinde temel bir referans model olarak

kullanılmıştır. Buna karşılık, DGKSA mimarisi ile nokta bulutu üzerindeki yerel komşuluk ilişkilerinin dinamik biçimde modellenmesi hedeflenmiştir. Bu iki mimari, farklı nokta örnekleme stratejileri altında değerlendirilmiş ve organ segmentasyonu açısından genelleme performansı, hesaplama maliyeti ve doğruluk oranları bakımından kapsamlı biçimde karşılaştırılmıştır.



3. MATERYAL VE YÖNTEM

Bu bölümde önerilen yöntemler ayrıntılı biçimde sunulmaktadır. Çalışmanın temel amacı, tıbbi görüntü segmentasyonunda nokta bulutu tabanlı derin öğrenme mimarilerinin uygulanabilirliğini araştırmak, bu yaklaşımların performansını literatürde yaygın olarak kullanılan ve yüksek başarı gösterdiği bildirilen voksel tabanlı modellerle karşılaştırmaktır. Bu kapsamda, böbrek ve pankreas segmentasyonu problemleri üzerinde çok aşamalı derin öğrenme yaklaşımları geliştirilmiş ve nokta bulutu ile voksel temsillerinin doğruluk, genellenebilirlik ve hesaplama verimliliği açısından sistematik biçimde değerlendirilmesi hedeflenmiştir. Ayrıca, voksel tabanlı mimariler aracılığıyla elde edilen İA'ların ince segmentasyon aşamasına daha etkili biçimde aktarılması amaçlanmaktadır.

Çalışmanın başlangıç aşamasında, nokta bulutu tabanlı derin öğrenme yöntemlerinin tıbbi görüntü segmentasyonu problemlerine uyarlanabilmesi amacıyla ön hazırlık niteliğinde bir çalışma yürütülmüştür. Bu doğrultuda, PointNet mimarisinin performansı öncelikle sınıflandırma problemleri üzerinde değerlendirilmiştir. Bu kapsamda ModelNet10, ModelNet40 ve MNIST veri setleri kullanılarak çeşitli deneyler gerçekleştirilmiştir. Bu aşama, nokta bulutu temsiline dayalı modellerin çalışma prensiplerinin anlaşılması ve bu modellerin tıbbi görüntü verilerine entegrasyonu açısından önemli bir temel oluşturmuştur.

Tıbbi görüntülerde nokta bulutu tabanlı yöntemleri uygulayabilmek için yüksek boyutlu verilerle başa çıkmak gerekmektedir. Bu nedenle, çok geniş hacimlere sahip 3B abdomen BT görüntülerinde doğrudan işlem yapmak yerine, ön işleme adımı olarak abdomen segmentasyonu gerçekleştirilmiştir. Bu işlemde kullanılan 3B U-Net modeli ile sadece abdomen bölgesini içeren İA'lar çıkarılarak veri boyutunun düşürülebileceği gösterilmiştir. Ayrıca bu sayede böbrek segmentasyonu aşamaları için daha yönetilebilir bir veri yapısı elde edilmiştir.

Abdomen segmentasyonu çalışmasında boyutun düşürülebileceği gözlemlendikten sonra, böbrek İA'larını bulmak amacıyla kaba segmentasyon adımı gerçekleştirilmiştir. Bu aşamada, sağ ve sol böbreklere ait bölgelerin yaklaşık konumlarını tespit etmek için yeni bir 3B U-Net modeli eğitilmiştir. Böylece böbreklerin ayrıştırılması sağlanmış ve ince segmentasyon işlemi için hedef bölgeler net biçimde belirlenmiştir.

Bu aşamadan sonra, kaba segmentasyon sonucunda elde edilen böbrek bölgeleri üzerinde detaylı (ince) segmentasyon işlemi gerçekleştirilmiştir. Bu ikinci aşamada, üç farklı derin öğrenme mimarisi değerlendirilmiştir: klasik voksel tabanlı 3B U-Net, nokta bulutu temsiline dayanan PointNet ve DGKSA. Nokta bulutu tabanlı modellerin uygulanabilmesi için, kaba segmentasyonla elde edilen böbrek bölgeleri bir ön işleme adımıyla nokta bulutu biçimine dönüştürülmüştür.

Ayrıca, çalışmada yalnızca böbrek segmentasyonu değil, farklı organlarda da nokta bulutu ve voksel tabanlı yaklaşımların performanslarının karşılaştırılması amaçlanmıştır. Bu kapsamda pankreas segmentasyonu problemine yönelik olarak çok aşamalı, yama tabanlı bir derin öğrenme yaklaşımı önerilmiştir. İlk aşamada, 256×256 boyutlu BT görüntüleri üzerinde yama tabanlı 3B ResUNet mimarisi kullanılarak pankreasın kaba konumu belirlenmiştir. İkinci aşamada ise bu bölgeye odaklanılarak voksel tabanlı U-Net, ResUNet ve TransUNet modellerinin yanı sıra, nokta bulutu temsiline dayalı PointNet ve DGKSA mimarileri ile ayrıntılı segmentasyon gerçekleştirilmiş ve elde edilen sonuçlar karşılaştırılmıştır.

Sonuç olarak, tasarlanan çok aşamalı yapı sayesinde bu tez kapsamında üretilen abdomen ilgi alanları ile böbrek ve pankreas lokalizasyonları etkili bir biçimde kullanılmıştır. Böylece, ince segmentasyon aşamasında 3B U-Net, ResUNet, TransUNet, PointNet ve DGKSA gibi farklı mimarilerin başarımları sistematik olarak karşılaştırılabilmiştir. Bu yaklaşım, tıbbi görüntü segmentasyonunda kullanılan farklı veri temsillerinin başka bir ifadeyle voksel tabanlı ve nokta bulutu tabanlı yöntemlerin doğruluk, genellenebilirlik ve uygulanabilirlik açısından bütüncül bir biçimde değerlendirilmesine olanak sağlamaktadır.

Bu bağlamda, Bölüm 3.1’de PointNet ile gerçekleştirilen sınıflandırma uygulamaları, Bölüm 3.2’de abdomen segmentasyonu, Bölüm 3.3’te böbrek segmentasyonu ve Bölüm 3.4’te pankreas segmentasyonu çalışmalarına ilişkin detaylar kapsamlı biçimde sunulmuştur.

3.1. PointNet ile Sınıflandırma Uygulamaları

Bu çalışmada, nokta bulutu tabanlı derin öğrenme mimarilerinin tıbbi görüntü segmentasyonu alanındaki potansiyelini değerlendirmeden önce, bu yöntemlerin temel sınıflandırma görevlerindeki performansları incelenmiştir. Bu doğrultuda, doğrudan nokta bulutu verisi üzerinde işlem yapabilen PointNet mimarisi tercih edilmiştir. Modelin

temel çalışma prensiplerini ve nokta bulutu temsiline olan duyarlılığını değerlendirmek amacıyla, literatürde yaygın olarak kullanılan ModelNet10, ModelNet40 ve MNIST veri setleri üzerinde kapsamlı deneyler gerçekleştirilmiştir. Bu aşama, nokta bulutu tabanlı mimarilerin farklı veri temsilleriyle olan etkileşimlerini analiz etmek, modelin genelleme yeteneğini gözlemlemek ve ilerleyen bölümlerde sunulacak tıbbi görüntü segmentasyonu uygulamaları için kavramsal ve teknik bir temel oluşturmak amacıyla planlanmıştır.

Bu kapsamda, iç mekân nesnelerini içeren ModelNet10 ve ModelNet40 veri setleri ile üç boyutlu rakamlardan oluşan MNIST veri seti kullanılmıştır. Deneysel çalışmalarda, PointNet mimarisinin döndürülmüş nesneleri doğru biçimde sınıflandırma yeteneği özellikle değerlendirilmiş; ayrıca farklı doğrulama stratejilerinin ve nokta örnekleme sayılarının sınıflandırma doğruluğu üzerindeki etkileri incelenmiştir. Elde edilen bulgular, nokta bulutu tabanlı mimarilerin genel performans özelliklerini ortaya koyarak, sonraki bölümlerde sunulan böbrek ve pankreas segmentasyonu deneylerine kavramsal ve metodolojik bir zemin hazırlamaktadır.

3.1.1. Kullanılan veri setleri

Çalışmada, önerilen yöntemlerin farklı veri türleri üzerindeki performansını değerlendirmek amacıyla üç farklı veri seti kullanılmıştır: ModelNet10, ModelNet40 ve MNIST.

3.1.1.1. ModelNet10 veri seti

ModelNet10, ModelNet40 veri setinin küçük ölçekli bir alt kümesi olup toplam 10 farklı nesne kategorisine ait 4.899 adet üç boyutlu CAD (Computer-Aided Design) modelinden oluşmaktadır. Veri setinde yer alan nesne sınıfları arasında banyo küveti (bathtub), yatak (bed), sandalye (chair), sıra (desk), komodin (dresser), gece lambası (night stand), sabit dolap (sofa), masa (table), tuvalet (toilet) ve monitör (monitor) gibi günlük yaşamda sık karşılaşılan iç mekân nesneleri bulunmaktadır.

ModelNet10 veri seti, Princeton ModelNet projesi kapsamında hazırlanmış olup, üç boyutlu nesne tanıma, sınıflandırma ve modelleme alanlarında standart bir veri seti (benchmark) olarak yaygın biçimde kullanılmaktadır. Nesneler, normalize edilmiş ve orijin etrafında hizalanmış şekilde depolanmakta; bu sayede farklı mimarilerde geometrik dönüşümlerden bağımsız bir biçimde kullanılabilir.

Bu çalışmada, ModelNet10 veri seti nokta bulutu tabanlı sınıflandırma performansının değerlendirilmesi amacıyla kullanılmıştır. Her modelin yüzeyinden rastgele örneklenen noktalar, PointNet mimarisine giriş olarak verilmiş; modelin farklı nokta örnekleme sayılarındaki (512, 1024, 2048) sınıflandırma başarımı analiz edilmiştir. Şekil 3.1’de ModelNet10 veri setinde yer alan bazı örnek nesne görselleri sunulmaktadır (<https://modelnet.cs.princeton.edu/>).



Şekil 3.1. ModelNet10 veri setinden örnek nesneler

3.1.1.2. ModelNet40 veri seti

ModelNet40 veri seti, Princeton Üniversitesi tarafından oluşturulmuş geniş kapsamlı bir 3B model koleksiyonudur. Veri seti, 40 farklı nesne kategorisine ait toplam 12.311 adet üç boyutlu CAD modelini içermektedir. Bu kategoriler arasında iç mekân nesneleri, araçlar, uçaklar, binalar, mobilyalar ve ev eşyaları gibi çok çeşitli sınıflar bulunmaktadır.

ModelNet40, üç boyutlu şekil sınıflandırma ve tanıma problemleri için en yaygın kullanılan standart veri setlerinden biridir ve nokta bulutu tabanlı derin öğrenme modellerinin performans değerlendirmelerinde referans benchmark olarak kabul edilmektedir.

Bu çalışmada, ModelNet40 veri seti, PointNet mimarisinin genel sınıflandırma kabiliyetini ve farklı geometrik dönüşümlere karşı dayanıklılığını değerlendirmek amacıyla kullanılmıştır. Ayrıca, modelin veri boyutu, örnekleme sayısı ve validasyon stratejilerine duyarlılığı analiz edilerek, tıbbi görüntü verilerine uygulanabilirliğini değerlendirmede temel bir referans oluşturulmuştur. Şekil 3.2’de ModelNet40 veri setinde yer alan bazı örnek nesne görselleri gösterilmektedir (<https://modelnet.cs.princeton.edu/>).




Şekil 3.2. ModelNet40 veri setinden örnek nesneler

3.1.1.3. 3B MNIST veri seti

3B MNIST veri seti, yaygın olarak kullanılan iki boyutlu (2B) MNIST veri setinin 3B forma dönüştürülmüş halidir. Klasik MNIST veri setinde yer alan el yazısı rakamların 2B piksel temsilleri, bu versiyonda nokta bulutu biçiminde üç boyutlu uzaya aktarılmıştır. Her rakam, belirli bir yoğunlukta örneklenen noktalarla temsil edilmekte olup, böylece 3B nokta bulutu tabanlı sınıflandırma modellerinin eğitiminde ve değerlendirilmesinde kullanılabilir hale gelmiştir.

Bu veri seti, PointNet ve benzeri nokta bulutu tabanlı mimarilerin farklı veri temsilleri üzerindeki genelleme kabiliyetini test etmek amacıyla sıklıkla tercih edilmektedir. 3B MNIST, özellikle geometrik dönüşümlere karşı dayanıklılık, nokta örnekleme yoğunluğunun etkisi ve modelin veri boyutuna duyarlılığı gibi faktörleri analiz etmek için uygun bir deneysel ortam sunmaktadır.

Bu çalışmada, 3B MNIST veri seti, nokta bulutu temsiline dayalı sınıflandırma performansının nispeten basit ancak kontrollü bir veri ortamında değerlendirilmesi amacıyla kullanılmıştır. Şekil 3.3'te, 3B MNIST veri setinde yer alan bazı örnek rakamların üç boyutlu nokta bulutu temsilleri gösterilmektedir (<https://www.kaggle.com/datasets/daavoo/3d-mnist>).



Şekil 3.3. 3B MNIST veri setine ait örnek el yazısı rakamların üç boyutlu nokta bulutu temsilleri

3.1.2. PointNet mimarisi

PointNet, nokta bulutu verileri üzerinde doğrudan çalışabilen ilk derin öğrenme mimarilerinden biridir. Bu mimarinin tasarımında, nokta bulutlarının doğası gereği sahip olduğu üç temel gereklilik gözetilmiştir (Qi ve ark., 2017a):


- **Dönüşüm değişmezlik:** Ağ mimarisi, girişteki 3B nesnenin döndürülmesi, çevrilmesi veya ölçeklenmesi gibi geometrik dönüşümlerden etkilenmemelidir.
- **Permütasyon değişmezlik:** Nokta bulutları pikseller gibi sıralı yapılar değildir. Bu nedenle ağın, giriş noktalarının sırasına duyarlı olması (yani permütasyonlara karşı değişmezlik göstermesi) gerekmektedir.
- **Noktalar arası etkileşimlerin yakalanması:** Her bir nokta, komşu noktalarla olan ilişkileri üzerinden anlamlı uzamsal özellikler taşır. Bu nedenle ağ, noktalar arası bağlamı da öğrenebilmelidir.

PointNet, giriş olarak n adet (x, y, z) koordinatlı noktayı alır ve doğrudan nokta bulutu üzerinde öğrenme yapar. Noktaların sırasına ve dönüşümüne karşı değişmezliği sağlamak için T-Net dönüşüm ağı kullanılmaktadır. Modelin genel mimarisi ve veri akışı Şekil 4.3'te şematik olarak sunulmuş olup, işlem adımları genel hatlarıyla şu şekilde özetlenebilir:

- **Adım 1:** İlk olarak, giriş noktalarına ait (x, y, z) koordinatları, 3×3 boyutlu bir dönüşüm matrisi öğrenen T-Net ağına uygulanır. Bu ağ, giriş nokta bulutunu

normalize ederek, döndürme ve öteleme gibi geometrik dönüşümlere karşı modele değişmezlik kazandırır.

- **Adım 2:** Dönüştürülmüş noktalar, paylaşımlı ÇKA'lar aracılığıyla nokta başına 64 boyutlu özellik vektörlerine dönüştürülür. Bu aşamada her nokta bağımsız olarak işlenir. Her katmanda yığın normalizasyonu ve ReLU aktivasyon fonksiyonu uygulanır.
- **Adım 3:** İlk ÇKA katmanından elde edilen 64 boyutlu özellikler, 64×64 boyutlu bir dönüşüm matrisi öğrenen ikinci bir T-Net ağına uygulanır. Bu dönüşüm, nokta özellik uzayında dönüşüm değişmezliğini artırmak amacıyla gerçekleştirilir.
- **Adım 4:** Özellik dönüşümünün ardından noktalar sırasıyla $64 \rightarrow 128 \rightarrow 1024$ boyutlu uzaylara haritalanır. Bu işlem, nokta bulutundaki karmaşık yapısal ilişkilerin daha yüksek boyutlu temsillerle ifade edilmesini sağlar. Bu katmanlar da yine nokta başına uygulanır ve paylaşımlı ağırlıklar kullanılır.
- **Adım 5:** Nokta bulutunun sırasız yapısı nedeniyle, simetrik bir fonksiyon olan maksimum havuzlama işlemi uygulanarak tüm noktalar arasından küresel bir özellik vektörü elde edilir. Bu işlem sonucunda model, noktaların sırasına duyarlı hale gelir ve tüm bulutu temsil eden 1024 boyutlu bir küresel özellik vektörü oluşturulur.
- **Adım 6:** Elde edilen küresel özellikler, tam bağlantılı katmanlar üzerinden sırasıyla 512, 256 ve son olarak sınıf sayısına (k) indirgenir. Her katmanda yığın normalizasyonu, ReLU ve Dropout uygulanarak genelleme yeteneği artırılır. Dropout tekniği, eğitim sırasında rastgele bazı nöronların devre dışı bırakılmasıyla aşırı öğrenmenin önüne geçilmesini sağlar (Srivastava, 2013). Son katmanda softmax aktivasyonu kullanılarak nokta bulutunun ait olduğu sınıf olasılıkları hesaplanır.



Şekil 3.4. Sınıflandırma problemlerinde PointNet mimarisi


3.1.2.1. PointNet mimarisinin dönüşümlere karşı değişmezliği

PointNet mimarisinde dönüşüm değişmezliği, T-Net adı verilen özel bir alt ağ tarafından sağlanmaktadır. T-Net, giriş nokta bulutunu uygun bir referans sistemine hizalayarak modelin döndürme, öteleme ve ölçekleme gibi geometrik dönüşümlerden etkilenmeden öğrenme yapmasını amaçlar.

Bu alt ağ, küçük ölçekli bir sinir ağı şeklinde yapılandırılmıştır ve giriş olarak n adet (x, y, z) koordinatlı noktayı alır. Her nokta, ardışık ÇKA katmanlarıyla işlenerek aşamalı olarak daha yüksek boyutlu bir özellik uzayına taşınır. Bu sürecin temel bileşenleri aşağıdaki şekilde özetlenebilir:

- **Adım 1:** Girdi $n \times 3$ boyutunda olup her biri üç koordinat (x, y, z) içeren noktalardan oluşur. Bu giriş, paylaşımlı ÇKA yapısı kullanılarak sırasıyla 64, 128 ve 1024 boyutlu özellik uzaylarına dönüştürülür.
- **Adım 2:** Elde edilen özellikler üzerinde maksimum havuzlama işlemi uygulanarak, her örneğe ait 1024 boyutlu küresel özellik vektörü elde edilir.
- **Adım 3:** Bu küresel özellik vektörü, tam bağlantılı katmanlardan geçirilerek sırasıyla 512, 256 ve 9 boyutlarına indirgenir.
- **Adım 4:** Son tam bağlantılı katmanda, 256×9 boyutunda bir eğitilebilir ağırlık matrisi (w) ve 9 boyutlu bias (b) terimi kullanılarak, matris çarpımı işlemi gerçekleştirilir.
- **Adım 5:** Bu işlem sonucunda elde edilen 1×9 boyutlu vektör, bias (sapma) terimiyle toplanarak yeniden 3×3 dönüşüm matrisi biçiminde şekillendirilir. Bu matris, giriş nokta bulutu üzerindeki dönüşüm (döndürme, ölçekleme, öteleme) varyasyonlarını telafi etmek amacıyla kullanılır.

Elde edilen bu dönüşüm matrisi, giriş nokta bulutu üzerinde doğrusal bir dönüşüm gerçekleştirir ve tüm noktaları aynı referans düzlemine hizalar. Böylece PointNet, uzamsal dönüşümlere karşı değişmezlik özelliğini kazanır. T-Net yapısı Şekil 3.5'te gösterilmektedir.



Şekil 3.5. T-Net yapısı

3.1.2.2. PointNet mimarisinin permütasyon değişmezliği

Nokta bulutları, doğası gereği yapılandırılmamış verilerdir ve uzamsal ilişkileri açısından belirli bir sıralamaya sahip değildir. Bu nedenle, nokta bulutu verisi n adet noktanın kümesi olarak ifade edilir ve bu noktaların sırasının değiştirilmesi, verinin geometrik içeriğini etkilemez. Matematiksel olarak bu durum, aynı noktalar kümesi için $n!$ adet farklı permütasyonun var olabileceği anlamına gelir.

Bir derin öğrenme modelinin bu tür veriler üzerinde kararlı biçimde çalışabilmesi için, ağına girdi noktalarının sırasına duyarlı (permütasyonlara karşı değişmez) olması gerekir. PointNet mimarisi, bu gerekliliği sağlamak amacıyla ağ yapısında simetrik fonksiyonlar kullanır.

Bu bağlamda, ağına her bir noktadan çıkardığı yerel özellikler, tüm noktalar üzerinde birleştirilmeden önce toplama (sum), ortalama havuzlama (average pooling) veya maksimum havuzlama (max pooling) gibi simetrik birleştirme fonksiyonlarından geçirilir.

Bu fonksiyonlar, girdinin sırasına bağlı olmayan işlemler oldukları için, herhangi bir noktalar dizilimi (örneğin $(p_1, p_2, \dots, p_n)$) yerine farklı bir permütasyon $(p_{\pi(1)}, p_{\pi(2)}, \dots, p_{\pi(n)})$ verilse dahi, çıktı aynı kalmaktadır.

PointNet'te bu amaçla en etkili simetrik fonksiyon olarak maksimum havuzlama (max pooling) tercih edilmiştir. Bu yöntem, her özellik boyutunda en yüksek aktivasyon değerini seçerek, tüm nokta bulutunun en baskın özelliklerini öne çıkarır (Qi ve ark., 2017a). Sonuçta, n adet giriş noktasının genel temsili olan sabit uzunlukta bir küresel özellik vektörü elde edilir. Bu vektör, nokta bulutunun bütünsel yapısını özetleyerek sınıflandırma veya segmentasyon aşamalarında kullanılmaktadır.

Bu yaklaşım sayesinde PointNet, nokta bulutunun sırasız doğasına uygun şekilde permütasyon değişmezliği (permutation invariance) özelliğini etkin biçimde sağlamaktadır.

3.1.3. Sınıflandırma problemlerinde kullanılan değerlendirme metrikleri

Sınıflandırma performansını değerlendirmek için doğruluk (accuracy), duyarlılık (recall), kesinlik (precision) ve F₁ skoru metrikleri kullanılmıştır. Bu metriklerin matematiksel ifadeleri Eşitlik (1) – (4)’te sırasıyla sunulmuştur:

- Doğruluk, modelin tüm tahminler içindeki doğru sınıflandırma oranını ölçer (Miller ve ark., 2024).
- Duyarlılık, pozitif sınıfların ne kadarının doğru tahmin edildiğini gösterir (Salmanpour ve ark., 2024).
- Kesinlik, pozitif tahminlerin ne kadarının gerçekten doğru olduğunu belirtir (Naidu ve ark., 2023).
- F1 skoru, duyarlılık ve kesinlik arasındaki dengeyi tek bir değerle özetleyen metriktir (Reinke ve ark., 2024).

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

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (2)$$

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

$$F_1 = \frac{2 \cdot \text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

Eşitlik (1)–(3)’te yer alan DP (doğru pozitif), model tarafından pozitif olarak tahmin edilen ve gerçekte de pozitif olan örneklerin sayısını ifade etmektedir. DN (doğru negatif), hem model tahmininin hem de gerçek etiketin negatif olduğu örnekleri; YP (yanlış pozitif), modelin pozitif olarak sınıflandırdığı ancak gerçekte negatif olan örnekleri; YN (yanlış negatif) ise modelin negatif olarak tahmin ettiği fakat gerçekte pozitif olan örnekleri göstermektedir. Bu dört değer, sınıflandırma sonuçlarının karmaşıklık matrisi (confusion matrix) üzerinden elde edilir. Doğruluk, genel model başarısını özetleyen basit bir ölçüt olmakla birlikte, sınıflar arasında dengesiz veri

dağılımı (class imbalance) bulunduğunda yanıltıcı sonuçlar verebilir (Reinke ve ark., 2022). Bu tür durumlarda duyarlılık ve kesinlik, modelin özellikle pozitif sınıf üzerindeki performansını ayrı ayrı değerlendirmeye olanak tanır. F₁ skoru ise bu iki metriği harmonik ortalama yoluyla birleştirerek, modelin hem yanlış pozitifleri hem de yanlış negatifleri ne ölçüde minimize ettiğine dair daha dengeli bir performans göstergesi sunmaktadır (Reinke ve ark., 2022).

3.1.4. Deneysel tasarım


Hiperparametreler, derin öğrenme modellerinin başarımını doğrudan etkileyen temel unsurlardır (Wu ve ark., 2015). Bu nedenle çalışmada kullanılan parametrelerin seçimi dikkatle yapılmıştır. PointNet ağı, Python ortamında PyTorch kütüphanesi kullanılarak uygulanmıştır. Eğitim sürecinde yığın boyutu (batch size, YB) 32, öğrenme oranı (ÖO) 0.001 olarak belirlenmiş ve optimize edici olarak Adam algoritması tercih edilmiştir. YB'nin 32 seçilmesi, eğitim süresi ile genelleme performansı arasında denge sağlamak içindir; küçük yığın boyutları daha istikrarlı ancak yavaş öğrenmeye, büyük boyutlar ise daha hızlı ancak genelleme yeteneği düşük modellere yol açabilmektedir (L. Yang ve Shami, 2020). ÖO ise ağırlıkların güncellenme hızını belirleyen kritik bir parametredir; yüksek değerlerde model kararsızlaşabilirken, düşük değerlerde gereksiz uzun süren bir öğrenme süreci oluşabilir (L. Yang ve Shami, 2020).

PointNet mimarisinin en önemli özelliklerinden biri, döndürülmüş nesneleri doğru biçimde sınıflandırabilme iddiasıdır. Bu iddiayı sınamak için nesneler belirli açılarda döndürülerek test edilmiştir. Eğitim sürecinde, veri setindeki nesneler 0°–360° aralığında rastgele açılarla döndürülerek ağa sunulmuştur. Böylece modelin dönüşümlere karşı değişmezlik özelliği incelenmiştir. Test aşamasında da rastgele döndürülmüş nesneler kullanılarak modelin sınıflandırma performansı değerlendirilmiştir. Ayrıca farklı validasyon stratejileri (%80–%20 ayırımı ve 10/20 kat çapraz doğrulama) ile nokta örnekleme sayılarının (1024 ve 512 nokta) sonuçlara etkisi karşılaştırmalı olarak raporlanmıştır.

3.2. Abdomen Segmentasyonu

Bu bölümde, derin öğrenme tabanlı segmentasyon modellerinde giriş verilerinin boyutunu azaltarak, işlem yükünü azaltmak ve modelin hedef bölgeye odaklanmasını

sağlamak amacıyla geliştirilen ön işleme yöntemi kapsamlı biçimde açıklanmaktadır. Yöntemin temel amacı, abdomen hacmine ait tıbbi görüntülerde bilgi içermeyen veya ilgisiz alanları ortadan kaldırarak yalnızca analiz açısından anlamlı olan abdomen İA'sının korunmasını sağlamaktır. Böylece hem veri boyutu ve hesaplama maliyeti optimize edilmekte hem de segmentasyon modelinin doğruluğu ve kararlılığı artırılmaktadır. Şekil 3.6.a'da bir kesiti gösterilen abdomen verilerinde, Şekil 3.6.b'de kırmızı ile işaretlenen bilgi içermeyen bölgelerin çıkarılması hedeflenmiş ve kırpma işleminin ardından elde edilmesi amaçlanan sonuç Şekil 3.6.c'de gösterilmiştir.




Şekil 3.6. Abdomen verilerinin ön işleme süreci: (a) ham abdomen kesiti, (b) kırmızıyla işaretlenmiş gereksiz bölgelerin gösterimi, (c) kullanışsız alanların çıkarılması sonrası elde edilen nihai ön işlenmiş veri

Abdomen hacmine ait referans görüntüler (etiketler, maskeler), 3B Slicer yazılımı kullanılarak elle oluşturulmuştur. Veri boyutunu ve hesaplama maliyetini optimize etmek amacıyla hem giriş görüntülerine hem de referans görüntülere doğrusal aşağı ölçekleme (linear downscaling) uygulanmıştır. Veri ve etiket hazırlığı tamamlandıktan sonra, hazırlanan veri seti derin öğrenme modeline girdi olarak verilmiştir (Adım 1). Segmentasyon için 3B U-Net mimarisi kullanılmış, veriler üzerinde tahminler üretilmiştir (Adım 2). Ardından, her bir 2B kesit için abdomen bölgesine ait sınırlayıcı kutu (bounding box), 8-bağlantılı (8-connectivity) Bağlantılı Bileşenler Analizi (Connected

Components Analysis, BBA) yöntemiyle belirlenmiştir. Yalnızca yatay ve dikey komşulukları dikkate alan 4-bağlantılı yöntemle kıyasla, 8-bağlantılı yaklaşım çapraz (köşegen) komşulukları da hesaba katar; böylece daha bütüncül ve sağlam yapılar elde edilir. Bu durum, tespit edilen bölgelerde parçalanmayı azaltmakta ve en büyük bağlantılı bileşenin abdomen bölgesini doğru şekilde temsil etmesini sağlamaktadır.

Her bir kesitte en büyük bağlantılı bileşenin seçilmesi ve bu yapının minimum ve maksimum koordinatlarına göre İA sınırlarının belirlenmesiyle, izole gürültü ya da artefakt gibi ilgisiz yapılar etkin biçimde dışlanırken ana abdomen bölgesi korunmuştur. Yoğunluk değişimlerine ve gürültüye duyarlı olabilen eşikleme ya da kenar tespiti temelli yöntemlerin aksine, topolojiye duyarlı 8-bağlantılı BBA yöntemi daha kararlı bir segmentasyon sağlamaktadır. Bu yaklaşım, abdomen bölgesini etkili biçimde kapsarken ilgisiz alanları dışlayarak bilgi kaybını en aza indirmektedir (Adım 3).


Son olarak, belirlenen sınırlayıcı kutu doğrusal olarak yukarı ölçeklenmiş ve kutu tarafından tanımlanan alan orijinal görüntüden kırılarak kaydedilmiştir (Adım 4). Ön işleme sürecinin genel iş akışı Şekil 3.7’de gösterilmektedir.




Şekil 3.7 Abdomen segmentasyonu iş akış şeması

3.2.1. Abdomen segmentasyonunda kullanılan veri seti

BT görüntülerinde abdomen bölgesinin segmentasyonu, anatomik sınırların belirgin olması nedeniyle ileri düzey uzmanlık gerektirmemektedir. Bu nedenle, abdomen bölgesine ait etiketleme işlemleri 3B Slicer yazılımı kullanılarak manuel olarak gerçekleştirilmiştir. Deneyimli bir Slicer kullanıcısı, her bir veriye ait abdomen bölgesi etiketlemesini ortalama 3–5 dakika içerisinde tamamlayabilmektedir. Kullanılan CHAOS veri setine ait bir örneğin aksiyal, koronal ve sagittal düzlemlerden alınmış kesitleri sırasıyla Şekil 3.8 (a), (b) ve (c)’de sunulmuştur. İlgili görüntüler üzerine bindirilmiş referans etiketler ile oluşturulan 3B referans maske ise Şekil 3.9’da gösterilmektedir.



Şekil 3.8. CHAOS veri setinin ilk örneğine ait abdomen görüntüleri: (a) aksiyal kesit, (b) koronal kesit ve (c) sagittal kesit



Şekil 3.9. CHAOS veri setinin ilk örneğine ait abdomen segmentasyonu: (a) aksiyal kesit üzerine bindirilmiş referans maske, (b) sagittal kesit üzerine bindirilmiş referans maske, (c) koronal kesit üzerine bindirilmiş referans maske ve (d) 3B referans maskesi

Eğitim verisi olarak; üç örnek dışında tüm veriler CHAOS veri setinin eğitim ve test bölümlerinden alınmıştır. Buna ek olarak, eğitim verisine dahil edilmek üzere AbdomenCT-1K veri setinden üç örnek seçilmiştir. Çizelge 3.1, eğitimde kullanılan CHAOS veri setinin özelliklerini sunarken (Kavur ve ark., 2021), Çizelge 3.2, eğitimde kullanılan üç örnek ve testte kullanılan 11 örneği içeren AbdomenCT-1K veri setinin özelliklerini göstermektedir (Ma ve ark., 2021).

AbdomenCT-1K veri setindeki verilerde dosya adları Veri_00001_0000 formatında ifade edilmektedir; bu çalışmada söz konusu örnekler kısaca Veri1 şeklinde adlandırılmıştır. Sağ tarafta yer alan 4 haneli numara tüm verilerde sabit olarak 0 olduğundan, bu bölüm çalışmada kısaltılarak gösterilmiştir.

Çizelge 3.1. CHAOS veri setine ait temel istatistiksel bilgiler

Özellik	BT
Veri sayısı	40
Görüntü düzlemi çözünürlüğü (h, w)	512 x 512
Derinlik boyunca kesit sayısı (d)	[78- 294]
Ortalama kesit sayısı (d)	160
Genişlik (w) ekseninde piksel aralığı (mm/voksel)	[0,54- 0,79]
Yükseklik (h) piksel aralığı (mm/voksel)	[0,54- 0,79]
Derinlik (d) ekseninde voksel kalınlığı (mm/voksel)	[2,0- 3,2]
Eğitim verileri	Tüm veriler

Çizelge 3.2. AbdomenCT-1K veri setine ait temel istatistiksel bilgiler

Özellik	BT
Veri sayısı	14
Görüntü düzlemi çözünürlüğü (h, w)	512 x 512
Derinlik boyunca kesit sayısı (d)	[32- 670]
Ortalama kesit sayısı (d)	119
Genişlik (w) ekseninde piksel aralığı (mm/voksel)	[0,71- 0,98]
Yükseklik (h) piksel aralığı (mm/voksel)	[0,71- 0,98]
Derinlik (d) ekseninde voksel kalınlığı (mm/voksel)	[0,5- 5]
Eğitim verileri	Veri 1,2,4
Test verileri	Veri 5,7,8,13,14,18,20,26,33,35,37

3.2.2. Bağlantılı bileşenler analizi


BBA ikili görüntüdeki her bağlı bileşenin (yani her nesnenin) tüm piksellerine benzersiz bir etiket atanmasını amaçlar. Bu nedenle, bağlantılı bileşen etiketleme, görüntü analizi, görüntü anlama, örüntü tanıma ve bilgisayarla görme için en önemli süreçlerden biridir (L. He ve ark., 2017). Bağlantılı bileşenlerin tanımlanmasında iki yaygın komşuluk kriteri kullanılmaktadır:

- **4-bağlantı:** Her piksel yalnızca yatay ve dikey komşuları (üst, alt, sağ, sol) ile ilişkilidir.
- **8-bağlantı:** Her piksel, yatay ve dikey komşuların yanı sıra köşegen komşularla da ilişkilidir.

Şekil 3.10'da (a) bölümünde 4 komşuluk, (b) bölümünde ise 8 komşuluk yapılarına ait temsili gösterimler sunulmaktadır. BBA algoritmasının temel prensibi, bu

komşuluk ilişkilerini kullanarak bir görüntüdeki piksellerin birbirleriyle bağlantılı olup olmadığını belirlemeye dayanır. Algoritma özetle şu adımlardan oluşmaktadır:

1. Görüntüde sıfırdan farklı değerlere sahip her piksel için komşuluk ilişkileri değerlendirilir.
2. Sıfırdan farklı komşusu bulunmayan pikseller, yeni bir bileşen olarak tanımlanır.
3. Komşuluk ilişkisi bulunan pikseller aynı bileşen altında birleştirilir.
4. Farklı etiketlere sahip komşu bölgeler tespit edildiğinde, bu bölgelerin aynı bileşene ait olduğu varsayılır ve etiketler birleştirilir.



Şekil 3.10. BBA'da temel gösterimler (a) 4 komşuluk yapısı, (b) 8 komşuluk yapısı

Bu tez çalışmasında BBA, doğrudan etiketleme amacıyla değil, segmentasyon sonrasında ilgili anatomik yapıya ait en büyük bağlı bileşenin belirlenmesi amacıyla kullanılmıştır. Bu sayede, segmentasyon sonucunda oluşabilecek küçük gürültü bölgeleri veya hatalı parçalanmalar elimine edilerek hedef anatomik yapının bütünlüğünün korunması amaçlanmıştır.


3.2.3. 3B U-Net

3B U-Net, X-ışını, BT, MRG ve ultrason gibi biyomedikal görüntülerin otomatik olarak segmentasyonu için güçlü bir derin öğrenme modelidir (Amiri ve ark., 2019; Pandey ve Gupta, 2022; Walsh ve ark., 2022). 3B U-Net, biri Kodlayıcı (Encoder-Analiz), diğeri ise Kod Çözücü (Decoder-Sentez) olmak üzere iki simetrik yolaktan oluşmaktadır (Çiçek ve ark., 2016). Analiz yolunda yer alan konvolüsyon (convolution) ve aktivasyon katmanları, farklı mekânsal ölçeklerde öznitelikleri öğrenerek bilgi çıkarımı yapmakta ve aynı zamanda öznitelik haritalarının boyutunu sınırlı tutmaktadır.

Buna karşılık, sentez yolu bu öznelikleri birleştirerek piksel düzeyinde segmentasyon tahminleri üretmektedir (Dorgham ve ark., 2022; Fatemeh ve ark., 2020; Pandey ve Gupta, 2022).

Analiz ve sentez yolları arasındaki atlamalı bağlantılar (skip connections), özellikle sınırlı miktarda veriyle çalışıldığında dahi başarılı sonuçlar elde edilmesini sağlamaktadır (Dorgham ve ark., 2022). Analiz yolunda her bir katman; iki adet $3 \times 3 \times 3$ konvolüsyon katmanı, bu katmanları izleyen doğrusal olmayan aktivasyon fonksiyonu (ReLU) ve her bir boyutta iki adım kaydırmalı (stride = 2) $2 \times 2 \times 2$ boyutunda bir maksimum havuzlama (max pooling) katmanından oluşmaktadır. Sentez yolunda ise her bir katman; her bir boyutta iki adım kaydırmalı $2 \times 2 \times 2$ boyutunda bir yukarı konvolüsyon (up convolution) işlemi, ardından gelen iki adet $3 \times 3 \times 3$ konvolüsyon katmanı ve bunları takip eden ReLU aktivasyonları içermektedir.

Bu çalışmada, Çiçek ve ark. (2016) tarafından önerilen 3B U-Net mimarisi temel alınmış, ancak çalışmanın özgül gereksinimlerine uygun şekilde bazı küçük değişiklikler yapılmıştır. Özellikle, veri setine özgü zorlukların üstesinden gelmek ve segmentasyon başarımını artırmak amacıyla alternatif kayıp fonksiyonları da araştırılmıştır. Kullanılan 3B U-Net mimarisi Şekil 3.11'de gösterilmektedir.



Şekil 3.11. 3B U-Net mimarisi

3.2.4. Segmentasyonda kullanılan değerlendirme metrikleri

Segmentasyon, genellikle bir görüntünün birden fazla bölgeye veya parçaya ayrılması süreci olarak tanımlanır. Bu işlemde, her bir piksel ortak özelliklerine göre belirli bir sınıfa atanır. Segmentasyon performansını değerlendirmek amacıyla çeşitli metrikler kullanılmakta olup, bu metrikler genel olarak üç ana grupta

sınıflandırılmaktadır: Tek eşikli sayma veya örtüşme tabanlı metrikler (single-threshold counting or overlap-based metrics), mesafeye dayalı metrikler (distance-based metrics) ve probleme özgü segmentasyon metrikleri (problem-specific segmentation metrics) (Reinke ve ark., 2022).

Tek eşikli sayma metrikleri model tarafından üretilen olasılık tabanlı segmentasyon çıktılarının belirli bir eşik değeri kullanılarak ikili maskelere (0 ve 1) dönüştürülmesi temelinde çalışır. Tek eşikli sayma metrikleri arasında yer alan DBK ve Jaccard İndeksi (Jİ), algoritma tahmin görüntüsü ile referans görüntü arasındaki örtüşmeyi değerlendirmek amacıyla kullanılır. Buna karşılık, Hausdorff Mesafesi (HM), Ortalama Simetrik Yüzey Mesafesi (OSYM) ve Hausdorff Mesafesi'nin yüzde 95'lik sınır değeri (HM95) gibi mesafeye dayalı metrikler, nesne sınırları arasındaki uzaklıkları nicel olarak değerlendirerek segmentasyon doğruluğunu ölçmeyi hedefler (Reinke ve ark., 2022).

DBK, model tahmini ile referans görüntü maskesi arasındaki örtüşme oranını ölçer (Lin ve ark., 2021). Literatürde segmentasyon algoritmalarının doğruluğunu değerlendirmek amacıyla en yaygın kullanılan metriklerden biridir (Liu ve ark., 2018; Survarachakan ve ark., 2022). DBK, 0 ile 1 arasında değer alır; 1 değeri mükemmel segmentasyonu ifade eder (Eşitlik 5). Burada A , model tarafından elde edilen segmentasyon çıktısını; B , referans (gerçek) görüntüyü; DP , DN , YP ve YN ise sırasıyla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif piksel sayılarını temsil etmektedir.

$$DBK = \frac{2|A \cap B|}{|A| + |B|} = \frac{2DP}{2DP + YP + YN} \quad (5)$$

Jİ, diğer adıyla Birleşim Üzerinden Kesişim (Intersection over Union, IoU), model tahmini ile referans görüntü maskesi arasındaki kesişim hacminin, birleşim hacmine oranı olarak tanımlanan bir benzerlik ölçüsüdür (Eşitlik 6) (Survarachakan ve ark., 2022).

$$JI = \frac{|A \cap B|}{|A \cup B|} = \frac{DP}{DP + YP + YN} \quad (6)$$

Mesafeye dayalı metrikler arasında yer alan Hausdorff Mesafesi (HM) ve Ortalama Yüzey Mesafesi (OSYM), segmentasyon sonucunun sınır doğruluğunu değerlendirmek için kullanılmaktadır. HM (Eşitlik 7), segmentasyon sınırındaki herhangi bir noktanın, referans (gerçek) sınırdaki en uzak en yakın noktasına olan mesafesini hesaplayarak en kötü sınır hatasını ölçer (Lin ve ark., 2021). OSYM ise (Eşitlik 10), segmentasyon sınırındaki her bir noktanın referans sınırına olan en yakın mesafesi ile referans sınırındaki noktaların segmentasyon sınırına olan en yakın mesafelerinin karşılıklı ortalaması olarak tanımlanır. Bu nedenle OSYM, iki sınır yüzeyi arasındaki ortalama farkı ölçer ve genel sınır tutarlılığı hakkında bilgi verir. Burada $S(A)$ ve $S(B)$, sırasıyla A ile gösterilen tahmin edilen segmentasyon hacminin ve B ile gösterilen referans segmentasyon hacminin sınırlarını ifade etmektedir (Reinke ve ark., 2024). HM ve OSYM metriklerinin küçük değerler alması, yüksek segmentasyon doğruluğunu gösterir.

Aykırı değerlerin etkisini azaltmak amacıyla kullanılan HM95, maksimum mesafe değerleri yerine bu değerlerin %95'lik yüzdelik diliminde yer alan mesafe değerini dikkate alır. Bu nedenle, HM95 değerleri her zaman HM değerlerinden daha küçüktür. HM95 formülü Eşitlik 9'da verilmiştir; burada $x_{0.95}$, maksimum mesafelerin %95'lik diliminde yer alan değeri temsil etmektedir:

$$HM(A, B) = \max\{h(A, B), h(B, A)\} \quad (7)$$

$$h(A, B) = \max_{a \in A} \left(\min_{b \in B} (a, b) \right) \quad (8)$$

$$HM95(A, B) = x_{0.95}\{h(A, B), h(B, A)\} \quad (9)$$

$$OSYM = \frac{1}{|S(A) + S(B)|} \left(\sum_{a \in S(A)} d(a, S(B)) + \sum_{b \in S(B)} d(b, S(A)) \right) \quad (10)$$

Görelî Hacimsel Fark (GHF), probleme özgü bir segmentasyon metriği olup, iki hacimsel nesne veya şekil arasındaki farkı ya da benzerliği nicel olarak değerlendirmek amacıyla kullanılır. GHF (Eşitlik 11), bir nesnenin hacminin diğerine göre ne ölçüde sapma gösterdiğini sayısal olarak ifade eder. Eşitlik 11'de yer alan A , tahmin edilen segmentasyon hacmini; B ise referans segmentasyon hacmini temsil etmektedir. Böylece GHF, tahmin edilen hacmin gerçek hacme göre ne kadar fazla veya eksik olduğunu

oransal olarak ortaya koymaktadır. Bu metrik, özellikle şekiller veya nesneler arasında hassas karşılaştırmaların gerekli olduğu uygulamalarda oldukça yararlıdır. Örneğin, tıbbi görüntülemelerde zaman içinde organ boyutu veya şeklindeki değişimlerin izlenmesinde ya da bilgisayar grafiklerinde yeniden yapılandırılmış 3B modellerin kalitesinin değerlendirilmesinde sıkça kullanılmaktadır (Rathour ve ark., 2021).

$$GHF = \pm \frac{|A| - |B|}{|B|} \quad (11)$$

3.2.5. Kayıp fonksiyonları

Tıbbi görüntü segmentasyonunda kayıp fonksiyonları, modelin öğrenme sürecinin temelini oluşturmaktadır. Bu fonksiyonlar, model tarafından üretilen tahmin ile referans (gerçek) maske arasındaki farkı ölçerek bu farkın eğitim sürecinde minimize edilmesini sağlar. Bu alandaki en önemli zorluklardan biri, sınıf dağılımının dengesiz olmasıdır; özellikle tümör, pankreas veya böbrek parankimi gibi küçük anatomik yapılar, arka plana göre çok daha az piksel içerdiğinden modelin öğrenmesini güçleştirmektedir. Kayıp fonksiyonları bu dengesizliği dengelemek ve küçük yapıları doğru biçimde öğrenebilmek için kritik bir rol üstlenir (Milletari ve ark., 2016). Bu durum, bazı anatomik yapılar ya da anormalliklerin veri setinde diğerlerine göre çok daha az temsil edilmesiyle ortaya çıkar. Bu dengesizliğin doğru şekilde yönetilememesi, algoritmanın performansını olumsuz etkileyebilir; nadir fakat klinik açıdan kritik öneme sahip yapıların yeterince tanınamaması gibi istenmeyen sonuçlara yol açabilir. Bu nedenle, sınıf dengesizliğinin ele alınması, tıbbi görüntü segmentasyon yöntemlerinin doğruluğu ve etkinliği açısından kritik öneme sahiptir.

Bununla birlikte, uygun bir kayıp fonksiyonunun seçimi, modelin öğrenme sürecini hem doğruluk hem de hız bakımından doğrudan etkileyen bir faktördür (Salehi ve ark., 2017; Solak ve ark., 2023). Özellikle Dice Kayıp Fonksiyonu (Dice Loss- DKF), hedef bölge ve arka plan pikselleri arasında ciddi dengesizlikler içeren veri setleri için oldukça etkili bir yaklaşımdır. Fokal Kayıp Fonksiyonu (FKF), sınıf dengesizliği sorununu, zor sınıflandırılan örneklerle daha fazla ağırlık vererek gidermeyi amaçlar. Tversky Kayıp Fonksiyonu (TKF) ise, DKF'nin bir türevi olarak geliştirilmiştir ve YP ve YN değerlerin ağırlığını ayarlayabilmek için iki hiperparametre (α ve β) içerir (Salehi ve ark., 2017; Solak ve ark., 2023).

Sonuç olarak, Fokal Tversky Kayıp Fonksiyonu (FTKF), FKF ve TKF'nin temel prensiplerini birleştirerek kolay sınıflandırılan piksellerin etkisini azaltırken, zor ve yanlış sınıflandırılan pikselleri daha fazla ön plana çıkarır. Bu çalışmada kullanılan DKF, Fokal Dice Kayıp Fonksiyonu (FDKF) ve FTKF gibi fonksiyonların tercih edilme nedeni; tıbbi görüntü segmentasyonunda karşılaşılan temel zorluklara etkili çözümler sunmalarıdır. Bu fonksiyonlar, sınıf dengesizliğini dengeleme, modelin daha hızlı ve stabil öğrenmesini sağlama ve segmentasyon doğruluğunu artırma konularında yaygın olarak kullanılmaktadır.

Her ne kadar İkili Çapraz Entropi (İÇE) ve sınır farkındalıklı (sınır duyarlı) kayıplar gibi alternatif kayıp fonksiyonları mevcut olsa da örtüşme temelli ve fokal temelli kayıplar, özellikle aşırı dengesiz sınıf dağılımlarında üstün performans göstermektedir. Bu nedenle, söz konusu tıbbi segmentasyon problemi kapsamında en uygun yaklaşımlar olarak bu kayıp fonksiyonları tercih edilmiştir (Azad ve ark., 2023; Solak ve ark., 2023). Söz konusu kayıp fonksiyonlarının matematiksel tanımları, 12'den 16'ya kadar olan eşitliklerde sunulmuştur:

$$DKF = 1 - \frac{2DP}{2DP + YP + YN} \quad (12)$$

$$TKF = 1 - \frac{DP}{DP + \alpha YN + \beta YP} \quad (13)$$

$$FTKF = \sum_c (1 - TI_c)^\gamma \quad (14)$$

$$FKF = - [(1 - p)^\gamma \cdot y \cdot \log(p) + p^\gamma \cdot (1 - y) \cdot \log(1 - p)] \quad (15)$$

$$FDKF = 0.5(FKF) + 0.5(DKF) \quad (16)$$

Bu formülasyonda (Eşitlik 15), p tahmin edilen olasılığı, y referans etiket değerini ve γ ise zor örneklerin etkisini kontrol eden odaklanma parametresini ifade eder. FDKF içerisinde DKF ve FKF'nin dengeli bir şekilde birleştirilmesi, modelin eğitim sürecinde hem sınıf dengesizliğiyle başa çıkmasını hem de ince yapısal detayları etkili bir şekilde öğrenmesini sağlar. Bu hibrit yaklaşım, modelin zor bölgeler üzerine odaklanma yeteneğini artırırken, tüm veri seti genelinde tutarlı ve yüksek bir performans sergilemesine olanak tanır.

3.2.6. Deneyisel tasarım

Abdomen segmentasyonu ön işleme kısmında gerçekleştirilen tüm deneyler, 3.60 GHz frekansında çalışan Intel® Core™ i9-9900K işlemcili, 64 GB RAM'e sahip ve NVIDIA GeForce RTX 2080 TI grafik işlem birimi içeren bir bilgisayar sisteminde yürütülmüştür. Tüm deneysel süreç, Windows 10 işletim sistemi üzerinde, TensorFlow-Keras 2.5.0 sürümü ve Adam optimize edicisi kullanılarak gerçekleştirilmiştir.

Deneyler iki temel aşamada yapılandırılmıştır. İlk aşamada, literatürde yaygın olarak kullanılan 3B U-Net mimarisi, farklı kayıp fonksiyonları kullanılarak eğitilmiştir. Bu kapsamda tercih edilen kayıp fonksiyonları DKF, FDKF ve FTKF'dir. Eğitimin başarısını doğrudan etkileyen hiperparametrelerden ÖO ve YB'nin etkisini incelemek amacıyla, modeller ÖO değerleri 0,001 ve 0,0001, YB değerleri ise 2 ve 4 olacak şekilde eğitilmiştir.

Bu çalışmada YB seçimleri, 3B U-Net modelinin yüksek çözünürlüklü hacimsel tıbbi verilerle eğitimi sırasında karşılaşılan bellek sınırlamaları göz önünde bulundurularak yapılmıştır. 3B segmentasyon problemlerinde, özellikle yüksek çözünürlüklü giriş verileri kullanıldığında, daha küçük yığın boyutları belleğe sığdırma açısından kaçınılmaz hale gelmektedir. Örneğin, Isensee ve ark. (2021), $128 \times 128 \times 128$ boyutlarındaki veri yamalarıyla gerçekleştirdikleri eğitimlerde yığın boyutunu 2 olarak belirlemiştir. Benzer şekilde, Çiçek ve ark. (2016) tarafından önerilen orijinal 3B U-Net çalışmasında da 1 veya 2 gibi düşük YB değerleri kullanılmıştır.

ÖO seçimleri ise daha önce yapılmış çalışmalarda önerilere ve modelin kararlılığı ile yakınsama hızı arasındaki dengeyi gözeterek belirlenmiştir. Örneğin Isensee ve ark.(2021), 3B U-Net eğitimi için 3×10^{-4} gibi orta seviyeli bir ÖO kullanırken, Liu ve ark. (2021) tarafından yapılan çalışmada 10^{-4} başlangıç ÖO tercih edilmiştir.

Her model, belirlenen 100 epok boyunca Adam optimizasyon algoritması kullanılarak, önceden öğrenilmiş ağırlıklar kullanılmadan (sıfırdan) eğitilmiştir. Eğitim süresince modelin doğrulama kümesi üzerindeki performansı izlenmiş ve her 10 epokta bir, en düşük kayıp fonksiyonu değerine sahip model kayıt altına alınmıştır.

Çalışmada kullanılan hiperparametrelere ilişkin detaylar, Çizelge 3.3'te sunulmaktadır.

Çizelge 3.3. Abdomen segmentasyonunda kullanılan 3B U-Net için kullanılan hiperparametreler

Hiperparametre	Değer/Yöntem
Katman sayısı	4 kodlayıcı, 4 kod çözücü
Konvolüsyon kernel boyutu	3
Maksimum havuzlama kernel boyutu	2
Adım boyutu	2
Ağırlık başlatma yöntemi	Ağırlıklar rastgele başlatılmış, ancak tüm modellerde aynı
Optimizasyon algoritması	Adam
Öğrenme oranı	$10^{-3}, 10^{-4}$
Kayıp fonksiyonu	DKF, FDKF, FTKF
Yığın Boyutu	2, 4

İlk aşamada en iyi senaryonun belirlenmesinin ardından, ikinci aşamada bu senaryo temel alınarak k-katlı çapraz doğrulama (k-fold cross-validation, k katlı ÇD) yöntemi uygulanmıştır. Test sonuçlarının değerlendirilmesi amacıyla, GHF, DBK, Jİ, Fokal Dice Katsayısı (FDK) ve Fokal Tversky Katsayısı (FTK) metrikleri hesaplanmış ve karşılaştırmalarda kullanılmıştır.

Bu metriklerden FTK, FTKF'nin değerinin 1'den çıkarılmasıyla; FDK ise FDKF değerinin 1'den çıkarılmasıyla elde edilmiştir. Böylece, bu iki benzerlik metriği de daha anlaşılır ve yorumlanabilir hale getirilmiştir.

3.3.Böbrek Segmentasyonu

Bu tez kapsamında, böbrek segmentasyonu amacıyla iki derin öğrenme tabanlı yaklaşım geliştirilmiştir.

Birinci yaklaşımda kullanılan yöntem iki aşamalı olarak tasarlanmıştır. İlk aşamada, 3B U-Net mimarisi kullanılarak her veriye özgü sağ ve sol böbrek İA'ları kaba segmentasyon yoluyla belirlenmiştir. Elde edilen İA'lar, veri yapısına göre çıkarılmış ve ince segmentasyon aşamasında bağımsız olarak işlenmiştir. Bu aşamada üç farklı mimari değerlendirilmiştir: voxel tabanlı 3B U-Net ve nokta bulutu tabanlı iki yöntem (PointNet ve DGKSA). Böylece, yalnızca voxel temsillerine dayanan yaklaşımların ötesine geçilerek nokta bulutu temsillerinin böbrek segmentasyonundaki etkinliği araştırılmıştır. Modeller, KiTS23 veri seti üzerinde eğitilmiş ve FLARE22 veri seti ile test edilerek genelleme performansı değerlendirilmiştir.

İkinci yaklaşımda ise voxel tabanlı mimarilerin performans karşılaştırmasını yapmak amacıyla çok aşamalı, yama tabanlı bir çerçeve geliştirilmiştir. Kaba segmentasyon aşamasında U-Net, AttUNet ve ResUNet mimarileri uygulanırken, ince

segmentasyon aşamasında bu mimarilere ek olarak MFFAU-Net ve TransUNet de kullanılmıştır. Bu modeller, dikkat mekanizmaları, artık bağlantılar ve dönüştürücü tabanlı öz-dikkat modülleri sayesinde çok ölçekli özellik çıkarımı, bölgesel odaklanma ve uzun menzilli bağlamsal ilişkilerin öğrenilmesi gibi avantajlar sağlamıştır.

Sonuç olarak, önerilen iki aşamalı yaklaşımlar hem vokseller hem de nokta bulutu temsillerinin karşılaştırmalı analizine olanak tanımış; böylece anatomik çeşitliliğin yüksek olduğu bölgelerde daha doğru ve genellenebilir böbrek segmentasyonu elde edilmesi hedeflenmiştir.

3.3.1. Kullanılan veri setleri

Bu tez kapsamında yürütülen çalışmalarda, böbrek segmentasyonu modellerinin eğitimi ve değerlendirilmesinde farklı kaynaklardan elde edilmiş medikal görüntü veri kümelerinden yararlanılmıştır. Böbrek segmentasyonu alanında yaygın olarak kullanılan bu veri kümeleri, modelin hem eğitim performansını hem de genelleme yeteneğini değerlendirmek amacıyla seçilmiştir. Bu kapsamda, önerilen yöntemlerin değerlendirilmesinde kullanılan veri setleri KiTS19, KiTS23 ve FLARE22 olup, bu veri setlerine ilişkin ayrıntılı bilgiler aşağıda sunulmaktadır.

3.3.1.1. KiTS19 veri seti

2019 Kidney Tumor Segmentation (KiTS19) veri seti, 210 veriye ait abdominal BT görüntülerinden oluşmakta olup, böbrek segmentasyonu konusunda yaptığımız ikinci çalışmada model geliştirme sürecinde birincil veri kaynağı olarak tercih edilmiştir. Toplam veri setinin 167 verisi eğitim, 42 verisi test için kullanılmıştır. Veri 160 numaralı örnek, diğerlerinden farklı olarak görüntü düzlemindeki (in-plane) çözünürlüğünün 512×512 boyutunda olmaması nedeniyle, uzamsal tutarlılığı etkileyebileceği gerekçesiyle analizden hariç tutulmuştur. Veri seti, <https://github.com/neheller/KiTS19> adresinden erişilebilir olup, her iki böbrek ve tümör bölgeleri için manuel segmentasyon etiketlerini içermektedir. Bu çalışmada, böbrek ve tümör bölgeleri birleştirilerek eğitim süreci boyunca tek bir “böbrek” sınıfı altında değerlendirilmiş; böylece segmentasyon problemi iki sınıflı (böbrek ve arka plan) bir yapı haline getirilmiştir.

3.3.1.2. Kits23 veri seti

Bu veri seti, toplamda 490 adet 3B BT görüntüsünden oluşmaktadır. Her bir BT kesiti, dört sınıfa ayrılarak segmente edilmiştir: böbrek, tümör, kist ve arka plan. Şekil 3.12’de, veri setinden örnek bir kesit sunulmakta olup mor renk böbrek dokusunu, mavi renk kisti ve yeşil renk tümörü temsil etmektedir. Genellikle tümörler kötü huylu (malign) kitleleri, kistler ise iyi huylu (benign) oluşumları ifade etmektedir. Bu çalışmada, böbrek, tümör ve kist bölgeleri birleştirilerek eğitim süreci boyunca tek bir “böbrek” sınıfı olarak değerlendirilmiş; böylece segmentasyon görevi iki sınıflı (böbrek ve arka plan) bir problem olarak ele alınmıştır. Veri setine <https://github.com/neheller/kits23> adresinden erişilebilmektedir.




Şekil 3.12. Kits23 veri setinden örnek bir kesit ve ilgili etiketler

3.3.1.3. FLARE22 veri seti

Bu çalışmada, modelin test ve genelleme performansını değerlendirmek amacıyla karın bölgesi organ segmentasyonu alanında yaygın olarak kullanılan Fast and Low-resource semi-supervised Abdominal oRgan sEgmentation (FLARE22) veri setinden faydalanılmıştır. FLARE22, karın bölgesine ait BT görüntülerinde organ segmentasyonu amacıyla oluşturulmuş, çeşitli yapılar içeren ve kapsamlı etiketlemeler barındıran bir veri setidir. Toplam 50 adet etiketli örnek içeren veri setinde; karaciğer, dalak, pankreas, sağ ve sol böbrek, mide, safra kesesi, yemek borusu, aort, alt vena kava, sağ ve sol adrenal bezler ile on iki parmak bağırsağı olmak üzere 13 farklı organ segmentasyon hedefi olarak tanımlanmıştır. FLARE22 veri setinde böbrek yapıları sağ böbrek için etiket 2, sol böbrek

için ise etiket 13 olarak tanımlanmış; diğer tüm organlara ait segmentasyonlar arka plan sınıfı altında birleştirilmiştir.

Veri setine <https://drive.google.com/drive/folders/130DVWqCFALnpHIqnT6aucNlwYygemNjV> adresinden ulaşılabilir. Kullanılan etiketlerin görsel temsili Şekil 3.13'te verilmekte, üç veri setine ait temel istatistiksel bilgiler ise Çizelge 3.4'te özetlenmektedir.



Şekil 3.13. FLARE22 organ etiketleri

Çizelge 3.4. Böbrek segmentasyonunda kullanılan veri setleriyle ilgili istatistikler


Özellikler	Kits19	Kits23	FLARE22
Veri Sayısı	210	490	50
Düzlem içi uzamsal çözünürlük (h, w)	512 x 512	512 x 512	512x512
Derinlik düzleminde bulunan kesit sayısı (d)	[29-1059]	[29-1059]	[71-113]
Ortalama d boyutu kesit sayısı	216	191	96
Genişlik (w) eksenli piksel aralığı (mm/voksel)	[0,44-1,04]	[0,44-1,04]	[0,64-0,98]
Yükseklik (h) eksenli piksel aralığı (mm/voksel)	[0,44-1,04]	[0,44-1,04]	[0,64-0,98]
Derinlik (d) eksenli piksel kalınlığı (mm/voksel)	[0,5-5]	[0,5-5]	[2,5- 5]

3.3.2. Böbrek kaba segmentasyonu

Kaba segmentasyon aşamasında böbrek bölgelerinin belirlenmesi için iki yaklaşım uygulanmış olup, birinci yaklaşım Bölüm 3.3.2.1'de, ikinci yaklaşım ise Bölüm 3.3.2.2'de ayrıntılı olarak açıklanmıştır.

3.3.2.1. Birinci yaklaşım

Yüksek çözünürlüklü BT görüntülerinden böbrek segmentasyonunun gerçekleştirilme süreci, Şekil 3.14'te adım adım gösterilen algoritma doğrultusunda, 3B U-Net mimarisi kullanılarak gerçekleştirilen kaba segmentasyon aşamasıyla başlatılmaktadır. Bu aşamada, böbrek dokusu içermediği belirlenen ilgisiz bölgeler görüntüden çıkarılarak hesaplama maliyeti azaltılmaktadır. Bu amaçla, BT hacminden yalnızca böbreklerin yer aldığı anatomik bölge seçilmiş ve gereksiz arka plan bilgisi elimine edilmiştir. Çalışmada, bu işlem kapsamında BT hacminin [150:450, 50:450, :] aralığında kalan kısmı seçilerek böbrek odaklı bir alt bölge oluşturulmuştur (Adım 1).



Şekil 3.14. Böbrek kaba segmentasyonunun aşamaları (birinci yaklaşım)

İkinci adımda, hesaplama maliyetini azaltmak amacıyla BT görüntüsü ile buna karşılık gelen referans maskesi $128 \times 128 \times 96$ boyutlarına yeniden ölçeklenmiştir (Adım 2). Sonrasında, görüntülerin başında ve sonunda yer alan, böbrek içermediği varsayılan ilk 16 ve son 16 dilim çıkarılarak analiz yalnızca anlamlı bölgelere odaklanacak şekilde daraltılmıştır (Adım 3).

Kaba segmentasyon süreci için eğitilen 3B U-Net modeli, KITS23 veri seti üzerinde FDKF kullanılarak eğitilmiştir. Eğitim sırasında ÖO 0,0001 ve YB 2 olarak belirlenmiştir. Modelin çıktısı hem sağ hem de sol böbreği tek seferde işleyen bir tahmin üretmektedir (Adım 4).

Böbrek bölgelerinin ayrıştırılması için 2B BBA uygulanmıştır. Bu işlem, her bir böbreğe ait İA'ları başarılı bir şekilde tanımlamak amacıyla gerçekleştirilmiştir (Adım 5). Kaba segmentasyon sonucu elde edilen enine kesit görüntülerde her iki böbrek de görünür


durumdadır. İlk olarak, olası kopuklukları veya ayrı parçaları ortadan kaldırmak için morfolojik genişletme işlemi uygulanmıştır. Ardından, sol böbreğe ait İA'nın tespiti için sağ böbrek maskelenmiş; benzer şekilde, sağ böbreğin İA'sı da sol böbrek maskelenerek elde edilmiştir. Böylece her iki böbreğe ait İA'lar sistematik olarak belirlenmiş ve karşılık gelen etiket verileriyle birlikte kaydedilmiştir. Bu işlemler sırasında piksel boyutu, NIFTI formatı ile uyumlu olacak şekilde korunmuştur.

Enine kesit düzleminde, böbrek alanı en büyük olan kesit merkez kesit olarak belirlenmiştir. Veri bazında toplam kesit sayıları farklılık gösterdiğinden, üst ve alt sınırlar orantılı olarak tanımlanmıştır. Örneğin, 96 dilimlik bir görüntü yığını için merkez dilimin öncesinden 35 ve sonrasında 35 olmak üzere toplamda 71 kesit seçilmiştir. Aynı işlem sağ böbrek için de tekrarlanarak veriler kaydedilmiştir.

Son olarak, İA'ları, daha önce uygulanan aşağı ölçekleme işleminin tersi uygulanarak yeniden yüksek çözünürlüklü boyutlara ölçeklenmiştir. Böylece, her bir böbreğe ait izole edilmiş bölge özgün BT çözünürlüğünde elde edilerek, ileri düzey segmentasyon işlemleri için kullanılmaya hazır hâle getirilmiştir (Adım 6).

3.3.2.2. İkinci yaklaşım

Yüksek çözünürlüklü BT görüntülerinde böbrek bölgelerinin tespiti, yama tabanlı derin öğrenme yöntemlerinden yararlanılan kaba segmentasyon aşamasıyla başlatılmaktadır (Şekil 3.15). Bu aşamada temel amaç hem bellek gereksinimini azaltmak hem de hesaplama verimliliğini artırmaktır. Bu doğrultuda, BT hacimleri ve bunlara ait etiketler öncelikle $128 \times 128 \times 128$ voksel boyutuna aşağı ölçeklenmiştir. (Adım 1). Ardından, her bir hacim $128 \times 128 \times 16$ boyutlarındaki örtüşen alt yamalara bölünerek modele girdi olarak verilmiştir. Bu yaklaşım, her bir alt hacim içinde yerel 3B uzamsal bilgilerin etkili biçimde yakalanmasını sağlarken, tam 3B modellerin gerektirdiği yüksek bellek yükünü de belirgin ölçüde azaltmaktadır.



Şekil 3.15. Böbrek kaba segmentasyonunun aşamaları (ikinci yaklaşım)

Bu kapsamda, kaba segmentasyon aşamasında 3B U-Net, 3B AttUNet ve 3B ResUNet mimarileri ayrı ayrı eğitilmiş ve elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir. Model eğitimi, KiTS19 veri seti üzerinde gerçekleştirilmiştir. Eğitim sürecinde FDKF, 0,0001 öğrenme oranı ve 1'lik YB kullanılmıştır (Adım 2). YB'nin 1 olarak seçilmesi, sınırlı donanım kapasitesine sahip sistemlerde eğitimin sürdürülebilmesi ve bellek yönetiminin optimize edilmesi amacıyla tercih edilmiştir (Çiçek ve ark., 2016).

Eğitim tamamlandıktan sonra, model her iki böbreği tek seferde işleyerek tahmin maskelerini oluşturmuştur (Adım 3). Segmentasyon çıktılarının bütünlüğünü artırmak amacıyla, bağlantısız veya parçalı bölgeleri birleştirmek için morfolojik genişletme (dilation) işlemi uygulanmıştır (Adım 4). Bu adımı izleyen 3B BBA ile sol ve sağ böbrekler ayrı anatomik yapılar olarak tanımlanmış ve birbirinden ayrıştırılmıştır (Adım 5).

İA'ların doğru şekilde belirlenebilmesi için, her böbrek bağımsız olarak işlenmiş; bu işlem sırasında karşı taraf maskelenerek yalnızca hedef böbreğe ait hacim korunmuştur. Segmentasyon sonucunda elde edilen hacimlerden, en büyük bağlantılı 3B bileşen, anatomik bütünlüğün korunması amacıyla nihai böbrek İA olarak seçilmiştir. Her iki böbrek için de aynı işlem tekrarlanmış ve sonuçlar, NIfTI formatındaki orijinal vokselle boyutu korunarak kaydedilmiştir.

Son adımda, belirlenen İA'lar önceden uygulanan aşağı ölçekleme işleminin tersine çevrilmiş ve orijinal BT çözünürlüğüne yeniden ölçeklenmiştir. Böylece, her bir böbreğe ait yüksek çözünürlüklü bölgeler anatomik doğruluğu korunarak yeniden

yapılandırılmış ve ileri düzey segmentasyon işlemleri için kullanıma hazır hâle getirilmiştir (Adım 6).


Birinci yaklaşımda, bilgi içermeyen piksellerin doğrudan elimine edilmesine dayalı özgün bir yöntem izlenmiştir. Bu yöntemde, BT hacmi üzerinde böbreklerin bulunduğu anatomik bölge önceden belirlenen koordinat aralığına göre kırpılarak gereksiz arka plan bilgisi dışlanmış ve böylece hem hesaplama maliyeti azaltılmış hem de modelin yalnızca ilgili bölgeye odaklanması sağlanmıştır. Ayrıca, 2B BBA uygulanarak, böbreklere ait en büyük bağlantılı yapılar tespit edilmiş; bu yapıların ön ve arka sınırları sabit bir uzaklık ölçütüne göre belirlenmiştir. Bu yaklaşım, temel olarak kaba segmentasyon sonucunda elde edilen maskeleri geometrik olarak daraltarak böbrek odaklı alt hacimler elde etmeye yöneliktir.

İkinci yaklaşımda ise, BT görüntüleri üzerinde yama tabanlı derin öğrenme stratejisi kullanılmıştır. Bu yöntemde, yüksek çözünürlüklü hacimlerin tamamını işlemek yerine, veri örtüşen küçük alt hacimlere bölünerek modele verilmiş ve bu sayede bellek verimliliği artırılmıştır. Kaba segmentasyon sonrası 3B BBA uygulanarak, sol ve sağ böbreklere ait İA'lar hacimsel bütünlük esas alınarak ayrıştırılmıştır. Böylece, böbreklerin anatomik sınırları daha hassas biçimde tanımlanmış ve her iki böbrek bağımsız olarak yeniden yapılandırılmıştır.

3.3.3. Böbrek ince segmentasyonu

3.3.3.1. Voksel tabanlı derin öğrenme yaklaşımı

Kaba segmentasyonun ardından Şekil 3.14 adım 6'da elde edilen sağ ve sol böbreklere ait İA'ları ve referans görüntü maskeleri kullanılarak iki farklı 3B U-Net modeli eğitilmiştir. İnce segmentasyon sürecine ilişkin genel iş akışı Şekil 3.16'da gösterilmektedir.



Şekil 3.16. Böbrek ince segmentasyonun aşamaları


Elde edilen böbrek İA'larının boyutlarındaki değişkenliği gidermek amacıyla, 7. adımda yeniden ölçekleme işlemi uygulanmıştır. Bu kapsamda, küçük boyutlu İA'lar yukarı ölçeklenmiş (büyütülmüş), büyük boyutlu olanlar ise aşağı ölçeklenmiş (küçültülmüş) $128 \times 128 \times 96$ boyutlarında standart bir pencereye uyarlanmıştır. Ölçeklenmiş giriş görüntüleri ve karşılık gelen etiket verileri, 8. adımda her bir 3B U-Net modelinin eğitilmesinde kullanılmış ve 9. adımda her iki modelden tahmin çıktıları elde edilmiştir. 10. adımda, 7. adımda uygulanan ölçekleme işleminin tersi gerçekleştirilerek tahmin edilen hacimler özgün boyutlarına geri döndürülmüştür. Son olarak, 11. adımda yeniden oluşturulan böbrek tahminleri, orijinal hacimlerdeki konumlarına yerleştirilmiş ve referans etiketlerle karşılaştırılarak model performansı değerlendirilmiştir.

3.3.3.2. Nokta bulutu tabanlı yaklaşım

PointNet ve DGKSA, girdi olarak nokta bulutlarını işlemek üzere tasarlanmış mimarilerdir. Bu nedenle, ilk adımda voksel biçiminde temsil edilen giriş görüntüsünün nokta bulutuna dönüştürülmesi gerekmektedir. Bu dönüşüm sırasında her vokselin x, y, z koordinatları ile gri seviye değerleri kaydedilmektedir.

Ardından, oluşturulan nokta bulutu segmentasyon ağına aktarılmakta ve böylece ağın eğitim süreci başlatılmaktadır. Model, her bir noktayı bağımsız olarak işleyip özelliklerini çıkarmakta, sonrasında bu özellikleri birleştirerek nihai çıktıyı üretmektedir. 3B U-Net mimarisi ile gerçekleştirilen ince segmentasyon görevine benzer şekilde, bu yaklaşımda da sağ ve sol böbrek için ayrı modeller eğitilmiştir.

Nokta tabanlı ağlar kullanılarak gerçekleştirilen ince segmentasyonun genel iş akışı Şekil 3.17'de gösterilmektedir.



Şekil 3.17. Nokta tabanlı ağlarla böbrek ince segmentasyon iş akışı

Bu çalışmada böbrek İA'ları, yüksek çözünürlüklü BT hacminden elde edildikten sonra, öncelikle $128 \times 128 \times 96$ vokselle boyutuna ölçeklenmiştir (Adım 7). Elde edilen hacim, tıbbi görüntülerin sahip olduğu uzamsal çözünürlük (spatial resolution) bilgileri dikkate alınarak gerçek dünya koordinatlarına dönüştürülmüştür. Bu aşamada, her bir vokselin x, y ve z eksenlerindeki fiziksel koordinatları (milimetre cinsinden) hesaplanmış, ardından her noktaya karşılık gelen gri seviye yoğunluk değeri eklenerek her noktayı tanımlayan dört bileşenli bir vektör $[(x, y, z, yoğunluk)]$ oluşturulmuştur. Bu süreç, hacimsel verinin nokta bulutu biçimine dönüştürülmesini sağlamıştır (Adım 8).

Oluşturulan nokta bulutları, iki farklı derin öğrenme mimarisine — PointNet ve DGKSA — giriş olarak sunulmuştur. Ancak doğrudan tam örneklemeli nokta bulutunun kullanımı GPU bellek kapasitesini aşabileceği için, veri alt bloklar halinde işlenmiştir.


- PointNet için, x ve y eksenlerinde 2 pikselde bir örnekleme yapılmıştır. Bu işlemden önce $128 \times 128 \times 96$ boyutunda olan hacim işlem sonucunda $64 \times 64 \times 96$ boyutuna indirgenmiş ve toplam 393216 nokta elde edilmiştir. Eğitim sırasında bu nokta bulutu, her biri 65536 nokta içeren 6 alt bloğa ayrılmış ve her blok modelin girişine ayrı ayrı sunulmuştur (Adım 9).
- DGKSA mimarisi için, bellek kısıtları nedeniyle x ve y eksenlerinde 3 pikselde bir örnekleme uygulanmıştır. Böylece toplam 177504 nokta oluşturulmuş; veri, bellek kullanımını optimize etmek için her biri 29584 nokta içeren 6 parçaya bölünmüştür. Bu alt bölünmüş noktalar, etiket bilgileriyle birlikte DGKSA ağına giriş olarak verilmiştir (Adım 9).

Her iki model için de sol ve sağ böbrekler ayrı ayrı eğitilmiştir, çünkü böbreklerin uzamsal konumu ve yapısal özellikleri farklılık göstermektedir. Böylece, her bir böbreğe özgü morfolojik farklılıkların model tarafından öğrenilmesi sağlanmıştır (Adım 9).

Test aşamasında, iki farklı senaryo uygulanmıştır:

1. Eksik örnekleme test: Eğitimde kullanılan örnekleme oranı korunarak değerlendirme yapılmıştır.
2. Tam örnekleme test: Başlangıçta atlanan tüm noktalar da dahil edilerek hacmin tamamı ($128 \times 128 \times 96$) yeniden taranmıştır. Böylece, eksik voksel bilgileri de nokta bulutuna dönüştürülerek modelin tüm hacim üzerinde performansı analiz edilmiştir.


Son olarak, PointNet ve DGKSA modellerinden elde edilen tahmin maskeleri yeniden hacimsel forma dönüştürülmüş ve böbrek segmentasyon çıktıları üretilmiştir (Adım 10). Bu genel işlem akışı, Şekil 3.18’de adım adım gösterilmiştir.



Şekil 3.18. Nokta bulutu tabanlı PointNet ve DGKSA mimarileri kullanılarak gerçekleştirilen böbrek segmentasyonu sürecinin akış şeması

3.3.3.2.1. PointNet segmentasyon ağı

PointNet segmentasyon mimarisi, her biri x, y, z koordinatları ve gri seviye değerleriyle tanımlanan n adet noktadan oluşan nokta bulutunu giriş olarak alır. Ağın temel amacı, her bir noktanın ait olduğu hedef sınıfı belirleyerek, nokta düzeyinde segmentasyon gerçekleştirmektir. PointNet ağ yapısının genel şematik gösterimi Şekil 3.19’da sunulmuş olup mimari, sekiz temel adımdan oluşmaktadır.



Şekil 3.19. PointNet segmentasyon ağı (Qi ve ark., 2017a)

Adım 1 – Nokta Bulutu Hizalama: Modelin ilk bileşeni, 4×4 boyutunda öğrenilebilir bir dönüşüm matrisi üreten T-Net ağından oluşmaktadır. Bu alt ağ, girişteki $n \times 4$ boyutundaki nokta bulutu matrisini uzamsal olarak düzenleyerek, farklı döndürme veya öteleme durumlarında dahi geometrik tutarlılığın korunmasını sağlar. Matematiksel olarak bu dönüşüm aşağıdaki şekilde ifade edilmektedir:

$$P' = P.T_1, T_1 \in R^{4 \times 4} \quad (17)$$

Eşitlik 17’de P , giriş nokta bulutu matrisini; T_1 ise ağ tarafından öğrenilen uzamsal dönüşüm matrisini temsil etmektedir.

Adım 2 – Yerel Özellik Çıkarımı: Her bir nokta, paylaşımlı bir ÇKA ağı aracılığıyla 64 boyutlu bir özellik uzayına dönüştürülür. Bu işlem, her noktanın kendi çevresel geometrik yapısından anlamlı yerel özelliklerin çıkarılmasını sağlar. Bu aşamada

tüm noktalarda aynı ÇKA ağı paylaşılır, böylece model parametre sayısı azalır ve nokta sırasından bağımsızlık korunur.

Adım 3 – Özellik Dönüşümü: İkinci bir T-Net ağı, elde edilen 64-boyutlu özellikleri giriş olarak alır ve 64×64 boyutlu öğrenilebilir bir dönüşüm matrisi uygular. Bu özellik dönüşümü, nokta özelliklerinin farklı yönelimlerde veya ölçeklerde de uzamsal olarak tutarlı kalmasını sağlar. Böylece model, farklı pozisyonlarda aynı geometrik yapıları daha doğru şekilde temsil eder.

Adım 4 – Yüksek Boyutlu Özellik Öğrenimi (ÇKA $64 \rightarrow 128 \rightarrow 1024$): Özellik dönüşümünden çıkan her nokta, sırasıyla 128 ve 1024 boyutlu tam bağlantılı katmanlardan geçirilir. Bu aşamada ağ, yerel özellikleri giderek daha soyut ve yüksek boyutlu temsillere dönüştürür.

Adım 5 – Küresel Özellik Vektörü: Nokta bulutları sırasız veri yapıları olduğundan, modelin aynı geometrik şekli farklı nokta sıralamalarında da tanıyabilmesi gerekir. Bu amaçla, simetrik bir toplama fonksiyonu olan maksimum havuzlama işlemi uygulanır. Bu işlem sonucunda, tüm nokta bulutunu temsil eden tek bir 1024 boyutlu küresel özellik vektörü elde edilir. Bu vektör, nesnenin bütünsel (küresel) geometrik yapısını özetler.

Adım 6 –Yerel ve Küresel Özelliklerin Birleştirilmesi: Segmentasyon görevi, her bir noktanın ait olduğu sınıfı belirlemeyi hedeflediği için hem yerel hem de küresel bilgilere aynı anda ihtiyaç duyar. Bu nedenle, her noktanın 64-boyutlu yerel özellik vektörü ile tüm bulutu temsil eden 1024-boyutlu küresel özellik vektörü birleştirilir (concatenation). Sonuçta her nokta için 1088 boyutlu birleşik özellik vektörleri oluşturulur.

Adım 7 –Birleşik Özelliklerin İşlenmesi ve Boyut Azaltımı: Birleştirilen 1088 boyutlu öznitelik vektörleri, paylaşımlı ÇKA blokları aracılığıyla kademeli olarak işlenir. Bu aşamada ağ, yüksek boyutlu birleşik özellikleri daha kompakt fakat anlamlı bir temsile dönüştürmek için iki ardışık ÇKA katmanı kullanır. İlk ÇKA katmanı öznitelik boyutunu 512'ye, ikinci katman ise 256'ya indirger. Böylece her bir nokta için sınıf ayrımını kolaylaştıran, daha yoğun ve yüksek ayırıştırma gücüne sahip bir öznitelik uzayı elde edilir.

Adım 8 – Çıkış katmanı ve olasılıklar: 256 boyutlu temsil, önce bir ÇKA aracılığıyla 128 boyuta indirgenir. Daha sonra son doğrusal katman bu 128 boyutlu gösterimi m adet sınıf çıkışına dönüştürür. Elde edilen ham skorlar softmax ile normalize edilerek her nokta için sınıf olasılık dağılımı elde edilir.

3.3.3.2.2. DGKSA mimarisi

PointNet mimarisi, nokta bulutu verisini doğrudan işleyebilmesi açısından önemli bir yenilik sunmakla birlikte, her bir noktayı bağımsız olarak ele alması nedeniyle yerel geometrik bağıntıları yeterli düzeyde modelleyememektedir. Bu sınırlılık, özellikle karmaşık morfolojiye sahip yapılar veya yüksek mekânsal detay gerektiren görevlerde performans kayıplarına yol açmaktadır (Qi ve ark., 2017b) . Bu eksikliği gidermek üzere, Wang ve ark. (2019) tarafından DGKSA önerilmiştir. DGKSA, nokta bulutu verisinin yerel bağlantısal ve geometrik ilişkilerini yakalayabilmek amacıyla, nokta kümelerini dinamik olarak güncellenen grafik yapıları şeklinde temsil eder.

Bu yaklaşımda, her bir nokta için K-en yakın komşu (K-Nearest Neighbors, KNN) algoritması kullanılarak bir yerel komşuluk grafiği oluşturulur. Bu grafik, noktanın komşularıyla olan mekânsal ilişkilerini kenar biçiminde ifade eder. Ardından, bu grafik üzerinde gerçekleştirilen kenar konvolüsyonu (EdgeConv) işlemi, her noktanın hem kendi özniteliklerini hem de komşu noktalarla arasındaki fark vektörlerini (bağıl konum ilişkilerini) bir arada değerlendirir.

DGKSA mimarisi, nokta bulutunun uzaysal dönüşümlerine karşı değişmezliği sağlamak ve yerel ilişkileri daha etkin biçimde yakalayabilmek amacıyla, PointNet'te kullanılan T-Net modülü yerine uzamsal kenar konvolüsyonu tabanlı bir dönüşüm ağı kullanmaktadır. Bu ağ, giriş verisi farklı dönüşüm veya rotasyonlara maruz kalsa dahi geometrik tutarlılığı koruyacak şekilde öğrenilebilir bir dönüşüm uygular.

DGKSA'nın temel bileşeni olan EdgeConv katmanı, her ağ katmanında komşuluk grafiğini dinamik biçimde yeniden oluşturarak, farklı ölçeklerdeki yerel yapıları ve yapısal ilişkileri modelleme yeteneği kazandırır. Bu dinamik güncelleme mekanizması, modelin hem yerel hem de küresel bağlam bilgilerini eşzamanlı olarak öğrenmesini mümkün kılar.

Sonuç olarak DGKSA, PointNet'in küresel özellik çıkarım kapasitesini korurken, yerel geometrik ilişkileri de etkin biçimde temsil edebilmekte; bu sayede nokta bulutu tabanlı segmentasyon ve sınıflandırma görevlerinde üstün performans sergilemektedir. DGKSA mimarisinin genel şematik gösterimi Şekil 3.20'de sunulmuş olup, yapı dokuz temel adımdan oluşmaktadır.

sağlar. Bu yöntem, modelin eğitim sürecini kararlı hâle getirir ve aşırı uyum (overfitting) riskini azaltır (Ioffe ve Szegedy, 2015).

Adım 3-4: İkinci ve üçüncü kenar konvolüsyon blokları, sırasıyla ÇKA (128,64) ve ÇKA (128,64) yapılarını kullanır. Her blokta, nokta komşuluklarından öğrenilen yerel öznitelikler işlenir ve üç farklı ölçekten yerel temsil vektörleri (x_1, x_2, x_3) çıkarılır.

Adım 5: Bu üç seviyeli yerel öznitelikler kanal boyutunda birleştirilir ve $n \times 192$ boyutunda bir tensör oluşturulur. Böylece model, farklı ölçeklerdeki yerel bağlam bilgilerini tek bir birleşik temsilde toplar.

Adım 6: Birleştirilen öznitelikler, 192 giriş kanalından 1024 çıkış kanalına sahip bir konvolüsyon katmanına aktarılır. Bu katman, veriyi yüksek boyutlu bir özellik uzayına dönüştürerek nokta bulutu içerisindeki karmaşık geometrik ilişkilerin daha derin seviyede öğrenilmesini sağlar. Ardından, küresel maksimum havuzlama işlemi uygulanarak tüm nokta bulutunu temsil eden 1024 boyutlu küresel özellik vektörü elde edilir. Bu katmandan sonra küresel maksimum havuzlama işlemi uygulanarak tüm nokta bulutunu temsil eden 1024 boyutlu küresel özellik vektörü elde edilir.

Adım 7: Küresel özellik vektörü, nokta sayısı kadar çoğaltılarak her noktanın küresel bağlam bilgisine erişimi sağlanır.


Adım 8: Bu temsil, yerel özniteliklerle (x_1, x_2, x_3) birleştirilir ve her nokta için hem yerel hem küresel bilgileri içeren $n \times 1216$ boyutunda birleşik bir özellik vektörü oluşturulur.

Adım 9: Son olarak, ÇKA (256,128, p) katmanı nokta başına sınıf skorlarını üretir. Burada p, çıktı sınıf sayısını ifade eder. Modelin çıktısı, her nokta için tahmin edilen sınıf olasılıklarını içeren (B, N, sınıf sayısı) boyutunda bir tensördür. Tez çalışmasında sınıf sayısı iki olarak belirlenmiş olup, bu sınıflar arka plan ve hedef organı (böbrek veya pankreas) temsil etmektedir.

3.3.3.3. Yama (patch) tabanlı derin öğrenme yaklaşımı

Kaba segmentasyonun ardından, ayrıntılı böbrek segmentasyonu beş farklı yama tabanlı 3B mimari (3B U-Net, 3B ResUNet, 3B AttUNet, 3B MFFAU-Net ve 3B TransUNet) kullanılarak gerçekleştirilmiş ve sonuçlar karşılaştırmalı olarak sunulmuştur. Kaba segmentasyon aşamasında elde edilen sol ve sağ böbrek İA'ları için ayrı modeller eğitilmiştir.

Yama tabanlı yaklaşım, genel işlem adımları bakımından voksel tabanlı yaklaşımla büyük ölçüde benzerlik göstermektedir. Ancak bu yöntemde, $128 \times 128 \times 96$ boyutundaki hacimsel böbrek görüntüsü, Şekil 3.21’de gösterildiği üzere 8. adımda altı ayrı parçaya bölünmekte ve her biri $128 \times 128 \times 16$ boyutunda olacak şekilde ağa sunulmaktadır. Bu strateji, modelin yerel uzamsal bağlamlara daha etkin biçimde odaklanmasını sağlarken, aynı zamanda hesaplama maliyetini de önemli ölçüde azaltmaktadır.



Şekil 3.21. Yama tabanlı böbrek ince segmentasyon aşamaları

Yama düzeyinde elde edilen segmentasyon sonuçları, daha sonra birleştirilip yeniden ölçeklenerek orijinal boyutlarına dönüştürülmektedir. Son aşamada, yeniden yapılandırılan böbrek segmentasyonları tam BT hacmi içerisindeki anatomik konumlarına entegre edilmekte ve elde edilen sonuçlar, referans 3B hacim ile nicel olarak karşılaştırılmaktadır.

3.4. Pankreas Segmentasyonu


Pankreas segmentasyonunda en belirgin güçlükler, organın küçük ve karmaşık morfolojisi, kişiler arasında belirgin anatomik farklılıklar göstermesidir (Yan ve Zhang, 2021). Şekil 3.22’de, MSD Task07 Pankreas veri setinde yer alan üç boyutlu pankreas etiketleri bu durumu görsel olarak örneklemektedir. Bu çalışmada, pankreas segmentasyonu problemine yönelik olarak çok aşamalı, yama tabanlı bir derin öğrenme yaklaşımı önerilmektedir. Önerilen yöntemin temel amacı, sınırlı donanım kaynaklarıyla

alıřan sistemlerde hem hesaplama aısından verimli hem de yksek doėrulukta segmentasyon sonuları elde etmektir.




řekil 3.22. MSD Task07 Pankreas veri setindeki farklı rneklere ait  boyutlu pankreas hacim grselleri

Yntemin ilk ařamasında, 256×256 boyutundaki BT grntleri zerinde yama tabanlı 3B ResUNet mimarisi kullanılarak pankreasın kaba konumu belirlenmiřtir. Bu ařama, tm hacim zerinde doėrudan segmentasyon yapılmasının neden olacaėı yksek hesaplama maliyetini azaltmakta ve modeli pankreas İA'sına odaklayarak daha verimli bir ėrenme sreci saėlamaktadır. řekil 3.23'te, (a) orijinal hacimden alınan rnek bir kesit, (b) ise n iřleme adımı sonrasında elde edilen ve modele giriř olarak kullanılan kırpılmıř hacimden bir kesit sunulmaktadır.



Şekil 3.23. MSD Task07 Pankreas veri setinde bulunan bir örneğe ait (a) orijinal 3B hacimden alınan aksiyal kesit ve (b) uygulanan ön işleme adımları sonrasında modele giriş olarak kullanılan kırpılmış hacimden alınan karşılık gelen kesit

İkinci aşamada, ilk aşamada belirlenen İA kullanılarak ayrıntılı (ince) pankreas segmentasyonu gerçekleştirilmiştir. Bu kapsamda, derin özellik çıkarımı ve dikkat (attention) mekanizmalarının avantajlarını birleştiren 3B U-Net, 3B ResUNet ve 3B TransUNet mimarileriyle karşılaştırmalı deneyler yürütülmüştür. Ayrıca, hacimsel verilerin yüzey temsillerini daha etkin biçimde değerlendirebilmek amacıyla, nokta bulutu tabanlı ağlar (PointNet ve DGKSA) da ince segmentasyon aşamasına dahil edilmiştir. Bu modeller, 3B nokta bulutu temsillerinden yerel geometrik özellikleri doğrudan öğrenebilme yetenekleri sayesinde, özellikle organ sınırlarının belirsiz olduğu bölgelerde daha ayrıntılı segmentasyon elde edilmesine katkı sağlamıştır. Şekil 3.24'te pankreas segmentasyonunda kullanılan işlem hattının akış şeması gösterilmektedir.



Şekil 3.24. Pankreas segmentasyonunda kullanılan çok aşamalı işlem hattının şematik gösterimi

Deneysel bulgular, önerilen çok aşamalı yaklaşımın hem MSD Task07 Pankreas hem de FLARE22 veri setlerinde yüksek doğruluk oranları elde ettiğini ve genel segmentasyon başarımında literatürdeki yöntemlerle rekabet edebilecek düzeyde sonuçlar sunduğunu göstermektedir. Ayrıca yöntem, hesaplama verimliliği açısından da güçlü bir alternatif oluşturarak, özellikle GPU belleği kısıtlı sistemlerde pratik bir çözüm önermektedir.

Bu bağlamda, Bölüm 3.4.1’de pankreas segmentasyonu görevinde kullanılan veri setleri, Bölüm 3.4.2’de pankreasın kaba segmentasyon süreci, Bölüm 3.4.3’te ise yama ve nokta bulutu tabanlı yaklaşımlar kullanılarak gerçekleştirilen ince segmentasyon aşaması açıklanmaktadır.

3.4.1. Veri setleri


Pankreas segmentasyonu için MSD Task07 Pankreas ve FLARE22 olmak üzere iki farklı veri seti kullanılmıştır.

3.4.1.1. MSD Task07 Pankreas veri seti

Medical Segmentation Decathlon (MSD) kapsamında sunulan Task07 Pankreas veri seti, pankreas segmentasyonu alanında yaygın olarak başvurulmuş bir referans benchmark olarak öne çıkmaktadır. Veri seti, toplam 281 kontrastlı abdominal BT hacminden oluşmaktadır. Çalışmamızda, bu hacimlerin ilk 240'ı eğitim, kalan 41'i ise test amacıyla kullanılmıştır. Eğitim setinde pankreas organına ait manuel olarak etiketlenmiş referans segmentasyon maskeleri bulunmaktadır.

Veri setinin çok merkezli yapısı, görüntü çözünürlüğü, kontrast, gürültü seviyesi, tarama protokolleri ve cihaz parametreleri açısından önemli farklılıklar içermektedir. Bu çeşitlilik, klinik ortamlarda karşılaşılan gerçek dünyadaki varyasyonları yansıttığından, geliştirilen derin öğrenme modellerinin genelleme yeteneğini test etmek açısından oldukça değerlidir. Ayrıca, pankreasın anatomik olarak küçük boyutlu ve çevre dokularla benzer yoğunluk özelliklerine sahip olması, bu veri seti üzerinde gerçekleştirilen segmentasyon görevlerini zorlu fakat bir o kadar da model duyarlılığını ölçmede anlamlı hale getirmektedir.

Bu bağlamda, MSD Task07 Pankreas veri seti hem veri çeşitliliği hem de segmentasyon zorluğu açısından pankreas segmentasyonu alanında geliştirilen yöntemlerin performansını karşılaştırmak için güçlü bir değerlendirme platformu sunmaktadır. Şekil 3.25'te, veri setinde yer alan farklı verilere ait ve değişen karışıklık (kontrast) değerlerine sahip bazı örnek kesitler gösterilmektedir.



Şekil 3.25. MSD Task07 Pankreas veri setinde farklı karışıklık değerlerine sahip verilerin örnek kesitleri

3.4.1.2. FLARE22 veri seti

FLARE22 (Fast and Low-resource semi-supervised Abdominal oRgan sEgmentation 2022) veri seti, pankreas ve diğer abdominal organların otomatik segmentasyonu için hazırlanmış güncel bir referans veri setidir. Veri seti, çok sayıda

kontrastlı ve kontrastı düşük abdominal BT hacmini içermekte olup, farklı klinik merkezlerden toplanmıştır; bu nedenle çözünürlük, kontrast, gürültü seviyesi ve cihaz parametreleri açısından yüksek çeşitlilik göstermektedir. FLARE22 veri seti, derin öğrenme modellerinin genelleştirilebilirliğini, hesaplama verimliliğini ve farklı ön işleme stratejilerinin etkinliğini değerlendirmek için yaygın olarak kullanılmaktadır. Kullanılan veri setlerinin özellikleri Çizelge 3.5’te gösterilmektedir.

Çizelge 3.5. Pankreas segmentasyonunda kullanılan veri setlerinin özellikleri

Özellikler	MSD Task07 Pankreas	FLARE22
Veri Sayısı	281	50
Düzlem İçi Uzaysal Çözünürlük (h, w)	512 x 512	512 x 512
Derinlikte Kesit Sayısı (d)	[37- 751]	[71- 113]
Ortalama d -boyutu (Kesit Sayısı)	95	96
Genişlik (w) ekseninde Piksel Aralığı (mm/voksel)	[0,61 – 0,98]	[0,64 – 0,98]
Yükseklik (h) ekseninde Piksel Aralığı (mm/voksel)	[0,61 – 0,98]	[0,64 – 0,98]
Derinlik (d) ekseninde Kesit Kalınlığı (mm/voksel)	[0,7- 7,5]	[2,5- 5]

3.4.2. Kullanılan mimariler ve özellikleri

3.4.2.1. 3B ResUNet

3B ResUNet, hacimsel tıbbi görüntüler üzerinde yüksek doğrulukta segmentasyon sonucu elde etmek amacıyla geliştirilmiş bir derin öğrenme mimarisidir (Diakogiannis ve ark., 2020). Bu model, U-Net mimarisinin kodlayıcı–kod çözücü (encoder–decoder) yapısını, artık bağlantılar ile birleştirerek daha derin ağların eğitilmesini kolaylaştırır ve gradyan sönümlenmesi (vanishing gradient) problemini önemli ölçüde azaltır.


Gradyan sönümlenmesi, derin sinir ağlarının eğitiminde sıkça karşılaşılan bir sorundur. Geriye yayılım (backpropagation) sırasında gradyan değerleri katmanlar arasında geriye doğru aktarılırken giderek küçülür ve bazı katmanlara ulaştığında neredeyse sıfıra yaklaşır. Bu durum, ilk katmanlardaki ağırlıkların güncellenmesini zorlaştırarak modelin öğrenme kapasitesini sınırlar. Sonuç olarak ağ, yeterli derinlikte olsa bile karmaşık temsilleri öğrenemez veya çok yavaş yakınsar (He ve ark., 2015).

Artık bağlantılar bu problemi hafifletmek amacıyla önerilmiştir. Her konvolüsyon bloğunda girdi, doğrudan çıkışa eklenerek bilgi akışı için alternatif bir yol oluşturur. Böylece ağ, katmanlar boyunca hem orijinal girdiyi hem de öğrenilen artık bilgiyi taşır. Bu mekanizma, gradyanların geriye doğru akışını kolaylaştırarak sönümlenmesini önler ve daha derin ağların etkin biçimde eğitilmesini sağlar (Diakogiannis ve ark., 2020).

Modelin kodlayıcı yapısı, sırasıyla 64, 128, 256 ve 512 filtre içeren dört adet konvolüsyon bloğundan oluşmaktadır. Bu bloklarda, uzamsal çözünürlüğün kademeli olarak azaltılması ve daha soyut temsillerin öğrenilebilmesi için maksimum havuzlama işlemi uygulanmıştır. Bununla birlikte, hacimsel tıbbi görüntülerde kesit (d) eksenindeki çözünürlük genellikle yükseklik ve genişlik eksenlerine kıyasla daha düşüktür. Bu nedenle, havuzlama işlemi yalnızca yükseklik–genişlik ($h - w$) düzleminde gerçekleştirilmiş ve böylece kesit eksenindeki bilginin gereksiz yere kaybolması engellenmiştir.

Ağın köprü (bottleneck) katmanında, 1024 filtre içeren bir artık blok yer almakta olup, kodlayıcıdan elde edilen soyut özelliklerin daha derin temsillerini üretir. Kod çözücü aşaması bu özellikleri yeniden uzamsal çözünürlüğe dönüştürür. Bu aşamada, Conv3DTranspose katmanlarıyla yalnızca $h - w$ düzleminde yukarı ölçekleme (upsampling) yapılır ve her adımda kodlayıcı tarafındaki karşılık gelen özellik haritalarıyla atlama bağlantıları (skip connections) üzerinden birleştirilir. Bu bağlantılar, düşük seviyeli uzamsal bilgilerin korunmasını sağlayarak sınır doğruluğunu artırır.

Son katmanda, iki sınıflı segmentasyon (organ ve arka plan) için sigmoid aktivasyon fonksiyonu kullanılır. Böylece her vokselin aitlik olasılığı 0 ile 1 arasında normalize edilir. Şekil 3.26’da pankreas segmentasyonunda kullanılan 3B ResUNet mimarisi görselleştirilmiştir.



Şekil 3.26. Kullanılan 3B ResUNet mimarisi

3.4.2.2. 3B TransUNet

3B TransUNet mimarisi, klasik 3B U-Net yapısının kodlayıcı–kod çözücü (encoder–decoder) mimarisini, dönüştürücü tabanlı dikkat mekanizmalarıyla birleştiren hibrit bir derin öğrenme modelidir (Chen ve ark., 2021). Bu yapı KSA’ların yerel uzamsal özellik çıkarım kapasitesini, dönüştürücü (transformer) mimarisinin küresel bağlamsal ilişki modelleme yeteneğiyle bütünleştirerek, karmaşık anatomik yapıların daha kapsamlı ve anlamlı bir biçimde temsil edilmesini sağlar.

Modelin kodlayıcı (encoder) bölümünde, ardışık 3B konvolüsyon, yığın normalizasyonu ve ReLU katmanlarından oluşan konvolüsyon blokları kullanılarak giriş hacmindeki yerel özellikler hiyerarşik biçimde çıkarılır. Bu aşamada model, düşük seviyeli kenar ve doku bilgilerini daha derin katmanlarda giderek daha soyut temsillere dönüştürür.


Chen ve ark. (2021) tarafından oluşturulan klasik TransUNet, kodlayıcı kısmı ResNet50 tabanlı olup artık bağlantılar içermektedir. Ancak bu çalışmada kullanılan 3B TransUNet yapısında, 3B hacimlerin gerektirdiği hesaplama maliyeti ve bellek sınırlamaları göz önüne alınarak, artık bağlantılar çıkarılmış ve kodlayıcı saf bir konvolüsyon bloğu dizisi olarak tasarlanmıştır.

Bu yaklaşım, modelin parametre sayısını azaltarak eğitim sürecini hafifletmekte ve özellikle sınırlı veri setlerinde aşırı öğrenme (overfitting) riskini azaltmaktadır. Ayrıca, derinlik boyunca kanal sayısının kademeli biçimde artırılması sayesinde, model farklı ölçeklerdeki uzamsal özellikleri yakalayabilmekte ve hacim içerisindeki yapısal çeşitliliği çok ölçekli biçimde öğrenebilmektedir.

Pankreas segmentasyonu görevinde ResUNet mimarisinde kullanıldığı gibi kodlayıcı kısmı, sırasıyla 64, 128, 256 ve 512 filtreye sahip dört konvolüsyon bloğundan oluşmaktadır. Bu bloklarda, uzamsal çözünürlüğü azaltmak ve semantik derinliği artırmak amacıyla maksimum havuzlama işlemi uygulanmıştır. Ancak hacimsel tıbbi verilerde d -ekseninde (kesit yönünde) çözünürlük genellikle $h - w$ düzlemine göre daha düşüktür. Bu nedenle maksimum havuzlama yalnızca $h - w$ düzleminde gerçekleştirilmiş, böylece kesit yönündeki bilgi kaybı en aza indirilmiştir.

Kodlayıcı ile kod çözücü arasında yer alan dönüştürücü modülü, TransUNet mimarisinin temel bileşenidir. Dönüştürücü yapısı, ilk olarak Vaswani ve ark. (2017) tarafından doğal dil işleme alanında önerilmiş olsa da tıbbi görüntüleme alanında yaygın biçimde kullanılmaktadır. Bu modülde, kodlayıcıdan elde edilen üç boyutlu özellik


haritaları önce yeniden şekillendirme (Adım 1) işlemiyle düzleştirilir ve her bir yama bir gömülü vektör olarak temsil edilir. Ardından, bu vektörler çoklu başlıklı öz-dikkat (multi-head self-attention, MHSA) mekanizmasına (Adım 2) aktarılır. Bu mekanizma, her yamanın diğer tüm yamalarla olan ilişkisini değerlendirerek hacim genelindeki uzun menzilli bağımlılıkların öğrenilmesini sağlar. Öz-dikkat katmanının çıkışı, artık bağlantı ile birleştirilir (Adım 3) ve ardından katman normalizasyonu (Layer Normalization) uygulanır (Adım 4). Böylece modelin öğrenme süreci dengelenir ve gradyan akışı stabilize edilir. Sonrasında, her yama temsili iki katmanlı bir İleri Beslemeli Ağ'dan (Feed-Forward Network) geçirilir (Adım 5). Bu aşama, dikkat mekanizmasından gelen bilgilerin doğrusal olmayan biçimde dönüştürülmesini sağlayarak modelin ifade gücünü artırır. Son olarak, çıktı temsilleri geri şekillendirme (3B yeniden düzenleme, Adım 6) işleminden geçirilerek orijinal hacim boyutlarına dönüştürülür. Böylece hem küresel bağlamı hem de yerel uzamsal ayrıntıları içeren zengin bir özellik haritası elde edilir. Bu yapı sayesinde modelden, yalnızca komşu vöksel bilgisine değil, organın tamamındaki küresel bağlamlara da duyarlı hale gelmesi beklenir. Pankreas segmentasyonunda kullanılan 3B TransUnet mimarisi Şekil 3.27'de gösterilmektedir.



Şekil 3.27. Kullanılan 3B TransUnet mimarisi

3.4.3. Kaba segmentasyon

Kaba segmentasyon aşamasında iki ayrı deneysel çalışma gerçekleştirilmiştir. İlk çalışmada, yalnızca MSD Task07 Pankreas veri setinden seçilen ilk 240 örnek kullanılarak 3B ResUNet ağı eğitilmiştir. İkinci çalışmada ise aynı 240 MSD verisine ek olarak FLARE22 veri setinden 10 örnek dahil edilerek eğitim yapılmıştır. Her iki çalışmada da test işlemleri, MSD Task07 Pankreas veri setinin son 41 örneği ve FLARE22 veri setinin son 40 örneği üzerinde yürütülmüştür. Kaba segmentasyonda, öncelikle Kurnaz ve ark. (2024) tarafından önerildiği şekilde pankreasın bulunduğu bölgeyi kapsayan 256×256 boyutunda pencereler çıkarılmıştır. Bu işlem, modelin ilgisiz arka plan piksellerinden etkilenmeden organ bölgesine odaklanmasını sağlamaktadır. Örnek bir BT kesitine ait orijinal görüntü, referans görüntü maskesi, kırılmış görüntü ve kırılmış maske örnekleri Şekil 3.28’de sunulmaktadır. Görüntüler, pankreas dokusunun yoğunluk aralığını vurgulamak amacıyla -240 ile $+100$ HU aralığına normalize edilmiştir. Bu yoğunluk aralığı, pankreas ve çevresindeki dokular arasındaki kontrast farkını artırarak modelin öğrenme sürecini desteklemektedir. Elde edilen bu ön işlenmiş veriler, ağı eğitiminde kullanılmış ve her iki deneyin sonuçları karşılaştırmalı olarak analiz edilmiştir.



Şekil 3.28. MSD Task07 veri setinden bir örnek için: (a) orijinal BT görüntüsü, (b) referans maske görüntüsü, (c) 256×256 boyutunda kırılmış BT görüntüsü ve (d) ilgili kırılmış maske örneği


3.4.4. İnce segmentasyon

Kaba segmentasyon aşamasında ilgili organın yaklaşık konumunu ve kapsadığı hacmi belirleyen İA'lar elde edilmiştir. Çizelge 3.6'da bu İA'ların yükseklik, genişlik ve derinlik boyutlarına ilişkin minimum–maksimum aralıkları ile ortalama ve standart sapma değerleri sunulmaktadır. Bu istatistiksel bilgiler, ince segmentasyon aşamasında kullanılacak optimal pencere boyutunun belirlenmesinde temel referans olarak kullanılmıştır.

Çizelge 3.6. Pankreas kaba segmentasyon sonucu kesilen pencerelerin istatistiksel özellikleri

Veri	Min -Maks Yükseklik	Min -Maks Genişlik	Min -Maks Derinlik	Ort - Std Yükseklik	Ort - Std Genişlik	Ort - Std Derinlik
Eğitim	44-156	74-257	16-80	91,07±21,05	157,74±31,34	34,25±9,13
Test	44-172	100-229	14-152	90,44±23,67	166,90±28,70	38,59±21,61

Eğitim ve test kümelerinden elde edilen istatistikler, İA'ların ortalama yüksekliğinin yaklaşık 91 piksel, ortalama genişliğinin ise yaklaşık 162 piksel olduğunu göstermektedir. İnce segmentasyonda kullanılan 3B TransUNet ve 3B ResUNet mimarilerinde dört aşamalı kodlayıcı ve çözücü katmanları bulunduğu için, giriş boyutlarının bu çoklu aşağı örnekleme işlemlerini kayıpsız karşılayabilmesi için 16'nın katı olacak şekilde seçilmesi gerekmektedir. Bu iki gereklilik birlikte değerlendirildiğinde, veri setindeki ortalama değerlere en yakın ve ağ mimarisine uyumlu pencere boyutu olarak 96×176 piksel belirlenmiştir. Böylece pencere boyutu, hem Çizelge 3.6'da sunulan boyut dağılımlarını temsil etmekte hem de modelin yapısal gereksinimlerini karşılamaktadır. Bu doğrultuda çıkarılan tüm İA'lar ve karşılık gelen maskeler, aşağı veya yukarı ölçekleme işlemiyle 96×176 boyutuna dönüştürülmüştür. MSD Task07 pankreas veri setinden seçilen örnek bir veriye ait BT hacminden alınan kesit için; orijinal görüntü, referans maske, İA'dan elde edilen kırpılmış görüntü ve karşılık gelen kırpılmış maske Şekil 3.29'da sunulmaktadır. Ardından eğitim verileri – 240 ile 100 HU aralığında normalize edilerek 3B TransUNet ve 3B ResUNet mimarileri eğitilmiştir.



Şekil 3.29. MSD Task07 veri setinden seçilen bir veriye ait: (a) orijinal BT görüntüsü, (b) ilgili referans maske, (c) ilgi alanının belirlenmesinin ardından elde edilen kırılmış BT görüntüsü ve (d) karşılık gelen kırılmış maske


Nokta bulutu tabanlı mimarilerin eğitiminde ise kaba segmentasyon adımının ardından, elde edilen pankreas İA'sı tüm örneklerde uzamsal tutarlılığı sağlamak amacıyla 96×176 boyutlarında sabit bir düzlemsel çözünürlüğe ölçeklenmiştir. Her bir BT hacmi değişken bir derinlik (d) değerine sahip olduğundan, bu değer gerektiğinde son dilimin kopyalanmasıyla 4'ün en yakın katına ayarlanmıştır. Bellek kullanımını verimli bir şekilde yönetebilmek için hacim, ardışık dört dilimden oluşan bloklara ayrılmış ve her blok $96 \times 176 \times 4 = 67584$ voksel içermiştir.

Her bir voksel için, ilgili voksel aralığı değerleri kullanılarak $[x, y, z]$ uzamsal koordinatları hesaplanmış ve yoğunluk değeri eklenerek $[x, y, z, \text{"yoğunluk"}]$ biçiminde öznitelik vektörleri oluşturulmuştur. Böylece her blok, 67584×4 boyutunda bir nokta bulutu matrisi olarak temsil edilmiştir.

PointNet mimarisi, 67584×4 boyutundaki nokta bulutu verisini doğrudan işleyebilmesine karşın, DGKSA mimarisi aynı giriş boyutuyla eğitildiğinde bellek sınırlamalarıyla karşılaşmıştır. Bu sorunu gidermek amacıyla, genişlik (w) ve yükseklik (h) eksenlerinde birer nokta atlanarak alt örnekleme stratejisi uygulanmış ve böylece DGKSA için giriş boyutu 16986×4 olarak belirlenmiştir. Başlangıçtaki yöntemin aksine, bu aşamada yeniden örnekleme işlemi uygulanmamış ve ağ yalnızca alt örneklenmiş

verilerle eğitilmiştir. Bununla birlikte, görselleştirme amacıyla Şekil 3.30 (a)'da uzamsal olarak alt örneklenmiş ve DGKSA mimarisinde kullanılan referans maskenin nokta bulutu, Şekil 3.30 (b)'de ise tam örneklenmiş etiket haritası gösterilmiştir.

Kullanılan mimari detayları böbrek segmentasyonu bölümünde 3.3.3.2.1 ve 3.3.3.2.2 başlıklarında sunulmuştur.



Şekil 3.30. Pankreas segmentasyonu için kullanılan referans noktaların görselleştirilmesi: (a) DGKSA mimarisinde kullanılan alt örnekleniş referans nokta bulutu, (b) PointNet mimarisinde kullanılan tam örneklenmiş referans nokta bulutu

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, gerçekleştirilen deneysel çalışmaların sonuçları ve bu sonuçların literatürle karşılaştırmalı tartışmaları sunulmaktadır. Çalışmalar beş ana başlık altında ele alınmıştır.

İlk olarak, 4.1. PointNet ile Sınıflandırma Sonuçları başlığı altında, nokta bulutu tabanlı PointNet mimarisinin farklı veri setleri üzerinde yürütülen sınıflandırma deneylerine ait nicel bulgular paylaşılmış ve mimarinin genel sınıflandırma performansı değerlendirilmiştir.

İkinci olarak, 4.2. Abdomen Segmentasyonu Sonuçları bölümünde, 3B U-Net tabanlı yöntemle gerçekleştirilen karın (abdomen) bölgesi segmentasyonuna ilişkin sonuçlar sunulmuştur. Bu kapsamda klasik eğitim sürecine ait nicel sonuçlar, çapraz doğrulama yöntemi ile elde edilen performans değerleri ve İA kırpma işleminden sonra elde edilen bulgular ayrı alt başlıklarda verilmiştir. Ayrıca görsel sonuçlar sunularak, segmentasyon başarısının nitel analizi yapılmış ve iki boyutlu derin öğrenme mimarilerinin performansları 3B U-Net mimarisi ile karşılaştırılmıştır.

Üçüncü olarak, 4.3. Böbrek Kaba Segmentasyon Sonuçları bölümünde, önerilen yöntem kapsamında gerçekleştirilen kaba böbrek segmentasyonuna ait deneysel sonuçlar paylaşılmıştır. Bu aşamada, İA kırpma işlemi sonrasında elde edilen nicel sonuçlar değerlendirilmiş ve kaba segmentasyonun sonraki aşamalara katkısı tartışılmıştır.

Dördüncü olarak, 4.4. Böbrek İnce Segmentasyon Sonuçları bölümünde, kaba segmentasyonla elde edilen bölge üzerinde uygulanan ince segmentasyon adımlarına yer verilmiştir. Bu kısımda 3B U-Net ile elde edilen sonuçlar, yama tabanlı 3B ağlarla yapılan deneysel bulgular ve nokta bulutu tabanlı ağların performansları karşılaştırmalı biçimde analiz edilmiştir.

Son olarak, 4.5. Pankreas Segmentasyonu Sonuçları bölümünde, pankreas organına yönelik hem kaba hem de ince segmentasyon deneylerine ilişkin nicel sonuçlar sunulmaktadır. Kaba segmentasyon sonrası elde edilen bölgeler üzerinde gerçekleştirilen İA kırpma işleminin etkisi değerlendirilmiş, ardından voksel tabanlı mimariler kullanılarak gerçekleştirilen ince segmentasyon sonuçları detaylandırılmıştır.

Bu bölümdeki temel amaç, farklı derin öğrenme mimarilerinin sınıflandırma ve segmentasyon görevlerindeki başarılarını kapsamlı biçimde değerlendirmek, önerilen çok

aşamalı yapının tıbbi görüntü segmentasyonundaki etkinliğini ortaya koymak ve elde edilen bulguları literatürdeki güncel çalışmalarla karşılaştırmalı olarak tartışmaktır.

4.1. PointNet ile Sınıflandırma Sonuçları

Bu çalışmada, PointNet mimarisinin performansını farklı validasyon stratejileri altında kapsamlı biçimde değerlendirmek amacıyla iki aşamalı bir deneysel süreç izlenmiştir. Birinci aşamada, ağ her bir veri seti için sıfırdan eğitilmiş ve gürültüsüz orijinal veriler kullanılarak üç farklı validasyon yöntemi uygulanmıştır: (i) klasik validasyon (%80 eğitim – %20 doğrulama), (ii) 10-kat çapraz doğrulama ve (iii) 20-kat çapraz doğrulama.

İkinci aşamada, veri setlerindeki nesneler rastgele açılarla döndürülmüş ve her bir nokta konumuna sıfır ortalamalı, %2 standart sapmalı Gaussian (normal) gürültü eklenmiştir. Bu işlem, modelin yalnızca belirli konum veya yönelimlere bağımlı kalmasını önleyerek genelleme kabiliyetini artırmayı hedeflemiştir. Gaussian gürültü, nokta bulutu üzerinde küçük rastlantısal konum sapmaları oluşturarak gerçek dünyadaki sensör kaynaklı ölçüm belirsizliklerini (örneğin LIDAR veya derinlik kameralarındaki hata paylarını) taklit etmektedir. Böylece modelin bu tür uzamsal varyasyonlara karşı daha kararlı bir biçimde öğrenmesi sağlanmıştır. Elde edilen bu yeni verilerle ağ yeniden eğitilmiş ve sonuçlar kayıt altına alınmıştır.

Elde edilen deneysel bulguların özetleri nicel olarak Çizelge 4.1’de verilmiştir. Çizelge 4.1 incelendiğinde, klasik validasyon yöntemiyle özellikle MNIST veri setinde gürültüsüz senaryolarda en yüksek doğruluk değerlerine ulaşıldığı görülmektedir. Buna karşın, ModelNet10 ve ModelNet40 veri setlerinde, özellikle gürültü eklenen deneylerde, 10-kat ve 20-kat çapraz doğrulama yöntemleri daha tutarlı ve yüksek doğruluk oranları sağlamıştır.

Çizelge 4.1. PointNet mimarisi için farklı validasyon stratejileri, ön işlem senaryoları ve veri setleri üzerinde elde edilen sınıflandırma performans metrikleri

Veri Seti	Ön işlem Gürültü ve Döndürme	Validasyon Türü	Doğruluk	Duyarlılık	Keskinlik	F ₁
MNIST	VAR	10 kat	0,90	0,91	0,90	0,90
		20 kat	0,92	0,92	0,92	0,92
		Klasik	0,91	0,91	0,91	0,91
	YOK	10 kat	0,92	0,92	0,92	0,92
		20 kat	0,95	0,95	0,95	0,95
		Klasik	0,98	0,98	0,98	0,98
ModelNet40	VAR	10 kat	0,91	0,89	0,87	0,88
		20 kat	0,91	0,89	0,87	0,88
		Klasik	0,86	0,82	0,80	0,80
	YOK	10 kat	0,94	0,93	0,91	0,91
		20 kat	0,96	0,94	0,94	0,94
		Klasik	0,90	0,87	0,84	0,84
ModelNet10	VAR	10 kat	0,93	0,90	0,90	0,90
		20 kat	0,95	0,94	0,92	0,93
		Klasik	0,91	0,89	0,87	0,88
	YOK	10 kat	0,95	0,94	0,92	0,93
		20 kat	0,97	0,95	0,94	0,94
		Klasik	0,96	0,95	0,94	0,94

Ayrıca, MNIST veri setinde en yüksek doğruluk gürültüsüz senaryoda ve klasik validasyon yöntemiyle %98 olarak elde edilmiştir. Buna karşılık, ModelNet10 ve ModelNet40 veri setlerinde, özellikle gürültü eklenen deneysel koşullarda, çapraz doğrulama yöntemleri hem daha tutarlı hem de daha yüksek performans sağlamıştır. Bu bulgular, çapraz doğrulamanın modelin genellenebilirliğini artırmada önemli bir rol oynadığını ve farklı veri setlerinde güvenilir bir performans değerlendirme stratejisi olarak öne çıktığını göstermektedir.

Çalışmanın ikinci aşamasında, nokta bulutu örnekleme yoğunluğunun PointNet'in sınıflandırma performansı ve genellenebilirliği üzerindeki etkisi incelenmiştir. ModelNet40 veri setine döndürme ve gürültü ekleme ön işlemleri uygulanmıştır. Ardından ağ, 512, 1024 ve 2048 nokta içeren farklı örnekleme senaryolarında eğitilmiştir. Elde edilen performans sonuçları Çizelge 4.2'de özetlenmiştir.

Çizelge 4.2. ModelNet40 veri setinde PointNet ile farklı nokta sayıları için farklı validasyon türleriyle elde edilen sonuçlar

Veri Seti	Validasyon Türü	Nokta Sayısı	Doğruluk	Duyarlılık	Kesinlik	F ₁
ModelNet40	Klasik	2048	0,88	0,84	0,84	0,83
	Klasik	1024	0,86	0,82	0,80	0,80
	Klasik	512	0,86	0,82	0,80	0,80
	20 kat ÇD	2048	0,93	0,91	0,91	0,91
	20 kat ÇD	1024	0,91	0,89	0,87	0,88
	20 kat ÇD	512	0,93	0,91	0,90	0,90
	10 kat ÇD	2048	0,88	0,85	0,84	0,84
	10 kat ÇD	1024	0,91	0,89	0,87	0,88
	10 kat ÇD	512	0,91	0,88	0,88	0,87

Çizelge 4.2 incelendiğinde, klasik validasyon altında nokta sayısının artmasıyla sınıflandırma doğruluğunun kısmen yükseldiği görülmektedir. Özellikle 512 ve 1024 nokta ile eğitimde doğruluk değerleri 0,86 civarında iken, 2048 nokta ile bu değer 0,88'e ulaşmıştır. Bu durum, daha fazla nokta içeren temsillerin nesne geometrisini daha iyi yakalayarak sınıflandırma başarımını bir ölçüde artırdığını göstermektedir. Öte yandan, 20-kat çapraz doğrulama uygulandığında, düşük nokta sayılarına (örneğin 512 nokta) rağmen yüksek doğruluk ve F₁ skorlarının elde edildiği gözlemlenmiştir. Bu bulgu, literatürde de sıklıkla vurgulanan bir durumu desteklemektedir; veri çeşitliliğini artıran çapraz doğrulama, modelin aşırı uyum (overfitting) riskini azaltarak genellenebilirliğini güçlendirmektedir (Charilaou ve Battat, 2022). Benzer şekilde, 10-kat çapraz doğrulama ile de tatmin edici performans değerleri elde edilmiştir; ancak 20-kat çapraz doğrulama, sonuçların daha kararlı ve güvenilir olmasını sağlamıştır.

Sonuç olarak, hem örnekleme yoğunluğu (nokta sayısı) hem de kullanılan validasyon stratejisi, PointNet mimarisinin sınıflandırma başarısını doğrudan etkileyen temel faktörlerdir. Bu durum, uygun validasyon yöntemlerinin, düşük nokta sayılarında dahi modelin yüksek doğrulukla çalışmasını mümkün kıldığını ortaya koymaktadır.

Çizelge 4.3, 1024 nokta kullanılarak gerçekleştirilen çalışmalarda literatürde raporlanan sınıflandırma doğruluklarını özetlemektedir. Bu çalışmada, ModelNet40 veri seti üzerinde PointNet mimarisi ile 20-kat çapraz doğrulama uygulanarak elde edilen en yüksek doğruluk değeri %91'dir. Literatürde yer alan benzer çalışmalarda, daha karmaşık ve derin yapılara sahip olan PointNet++ mimarisi %92 doğruluk değeri ile raporlanmış, ReCon++, Mamba3D ve PointView-GCN gibi gelişmiş modeller ise sırasıyla %95, %95,1 ve %95,4 oranlarına ulaşmıştır.

Çizelge 4.3. ModelNet40 veri seti üzerinde PointNet, önerilen yöntem ve literatürdeki diğer çalışmaların doğruluk karşılaştırması

Veri Seti	Çalışma	Nokta Sayısı	Doğruluk
ModelNet40	PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation (Qi ve ark., 2017a)	1024	0,89
	PointNet++: Deep hierarchical Feature Learning on Point Sets in a Metric Space (Qi ve ark., 2017b)	1024	0,92
	A Graph-CNN for 3d Point Cloud Classification (Yingxue Zhang ve Rabbat, 2018)	1024	0,895
	Using Deep Learning in Semantic Classification for Point Cloud Data (Yao ve ark., 2019)	1024	0,93
	Universal 3D Object Understanding for Embodied Interaction (Qi ve ark., 2024) (ReCon++)	1024	0,95
	Mamba3D: Enhancing Local Features for 3D Point Cloud Analysis via State Space Model (Han ve ark., 2024)	1024	0,951
	Pointview-Gcn: 3D Shape Classification With Multi-View Point Clouds (Mohammadi ve ark., 2021)	1024	0,954
	PointNet - 20 Kat ÇD (bu çalışma)	1024	0,91

Bu yüksek doğruluk değerleri, modellerin daha fazla parametreye sahip olmaları ve dolayısıyla daha yüksek hesaplama maliyetleri gerektirmeleriyle ilişkilidir. Buna karşın, PointNet, daha basit yapısına rağmen düşük hesaplama yükü ve hızlı eğitilebilirliği sayesinde, ModelNet40 sınıflandırma probleminde verimlilik ve doğruluk dengesini en iyi şekilde sağlayan mimarilerden biri olarak öne çıkmaktadır.

Çizelge 4.4'te, ModelNet40 veri seti üzerinde daha az nokta örnekleme durumunda literatürde raporlanan sınıflandırma doğrulukları ile, bu çalışmada elde edilen sonuçlar sunulmaktadır. Literatürde yer alan PointNet++ (Qi ve ark., 2017b) ve Graph-CNN (Yingxue Zhang ve Rabbat, 2018) modelleri 512 nokta kullanılarak sırasıyla %90 doğruluk oranına ulaşmıştır. Bu çalışmada ise aynı koşullar altında, PointNet mimarisi 10 kat ÇD ile %91, 20 kat ÇD ile %93 doğruluk oranı elde etmiştir. Bu sonuçlar, örnekleme yoğunluğu azaltıldığında dahi önerilen modelin yüksek genelleme kapasitesine sahip olduğunu ve farklı veri alt kümelerinde tutarlı performans sergilediğini göstermektedir. Dolayısıyla, PointNet mimarisinin uygun eğitim stratejileri ve çapraz doğrulama düzenleriyle desteklenmesi, sınırlı nokta bulutu örneklerinden anlamlı geometrik özelliklerin öğrenilmesini mümkün kılmaktadır.

Çizelge 4.4. ModelNet40 veri seti düşük örnekleme yoğunluğunda (512 nokta) literatürde raporlanan ve bu çalışmada elde edilen sınıflandırma doğruluklarının karşılaştırılması


Veri Seti	Çalışma	Nokta Sayısı	Doğruluk
ModelNet40	PointNet++: Deep Hierarchical Feature Learning on Point Sets in a Metric Space (Qi ve ark., 2017b)	512	0,90
	A Graph-CNN for 3d Point Cloud Classification (Yingxue Zhang ve Rabbat, 2018)	512	0,90
	PointNet- 10 Kat ÇD	512	0,91
	PointNet- 20 Kat ÇD	512	0,93

4.2. Abdomen Segmentasyonu Sonuçları

Bu bölümde, abdominal bölge segmentasyonu için gerçekleştirilen deneylerde kullanılan farklı kayıp fonksiyonlarının ve eğitim stratejilerinin hesaplama maliyeti üzerindeki etkileri incelenmiştir. Elde edilen sonuçlar, kullanılan kayıp fonksiyonunun hesaplama maliyeti üzerinde sınırlı bir etkiye sahip olduğunu göstermektedir; GPU kullanımı ve eğitim süresi, farklı kayıp fonksiyonları arasında belirgin bir farklılık göstermemektedir. Buna karşın, hesaplama verimliliğini en çok etkileyen unsurun YB olduğu gözlemlenmiştir. Daha büyük YB değerleri, genellikle bir iterasyonda daha fazla örneğin işlenmesine olanak tanıyarak eğitim süresini kısaltmış; ancak bu durum daha fazla GPU belleği gerektirirken, mevcut donanım kaynaklarının daha verimli kullanılmasını sağlamıştır.

Şekil 4.1’de, farklı kayıp fonksiyonları (DKF, FDKF, FTKF) için eğitim metodu ve yığın boyutuna bağlı olarak elde edilen eğitim süreleri sunulmaktadır. Sonuçlar, özellikle 5 katlı çapraz doğrulama yönteminde en düşük eğitim sürelerinin elde edildiğini, buna karşılık 10 katlı ÇD uygulandığında artan yineleme sayısı nedeniyle bazı durumlarda klasik eğitime kıyasla daha uzun sürelerin ortaya çıktığını göstermektedir. Ayrıca YB’nin 2’den 4’e çıkarılması, tüm kayıp fonksiyonlarında eğitimin daha hızlı tamamlanmasına katkı sağlamıştır. Bu durum, derin öğrenme modellerinin eğitiminde YB’nin hem hesaplama verimliliği hem de donanım kaynaklarının kullanım düzeyi üzerinde belirleyici bir parametre olduğunu ortaya koymaktadır. Bununla birlikte, YB’nin artırılması GPU bellek gereksinimini yükselttiğinden, sınırlı belleğe sahip sistemlerde donanım kısıtı oluşturmaktadır. Dolayısıyla YB seçimi, hesaplama hızı ile donanım kapasitesi arasında bir denge (trade-off) gerektirmektedir. Bu çalışmanın bulguları da uygun YB değerinin, sistem belleğinin izin verdiği sınırlar içinde eğitim süresini

minimize ederken modelin kararlılığını ve genel performansını koruyacak biçimde belirlenmesi gerektiğini doğrulamaktadır.



Şekil 4.1. Abdomen segmentasyonunda farklı kayıp fonksiyonları için farklı eğitim metotları (klasik, 5 katlı ÇD, 10 katlı ÇD) ve yığın boyutuna (2 ve 4) göre elde edilen yaklaşık eğitim süreleri: (a) DKF, (b) FDKF, (c) FTKF

4.2.1. Klasik eğitime ait nicel sonuçlar

Abdomen segmentasyonu için gerçekleştirilen klasik eğitimde, 3B U-Net modelinin DKF, FDKF ve FTKF kullanılarak eğitilmesinin etkinliği değerlendirilmiştir. Bölüm 3.2.1’de açıklanan veri hazırlama süreci doğrultusunda, CHAOS veri setinden seçilen 40 örnek ile AbdomenCT-1K veri setinden alınan 3 örnekten oluşan toplam eğitim

verisi üzerinde %90–%10 oranında bir ayırım gerçekleştirilmiştir. Buna göre verilerin %90'ı modelin eğitimi için kullanılırken, kalan %10'luk bölüm doğrulama (validasyon) amacıyla ayrılmıştır. Çalışmanın ilk aşamasında, iki farklı YB, iki farklı ÖO ve üç ayrı kayıp fonksiyonunun kombinasyonlarından oluşan çeşitli deneysel senaryolar altında model eğitimleri gerçekleştirilmiştir. Bu deneysel yapı kapsamında, her bir senaryoya karşılık gelecek şekilde toplam 12 ayrı model eğitilerek değerlendirilmiştir.

Eğitilen bu modeller, AbdomenCT-1K veri setinden alınan 11 ayrı test verisi üzerinde test edilmiştir. Çizelge 4.5, klasik eğitim süreci sonucunda elde edilen ortalama nicel test sonuçlarını özetlemektedir. Elde edilen sonuçlar, farklı parametreler ve kayıp fonksiyonlarının model performansı üzerindeki etkilerini karşılaştırmalı bir biçimde ortaya koymaktadır.

Çizelge 4.5. Abdomen segmentasyonunda 3B U-Net ile klasik eğitimden elde edilen ortalama nicel test sonuçları

Yığın Boyutu	Metrikler [%]	Kayıp Fonksiyonu DKF		Kayıp Fonksiyonu FDKF		Kayıp Fonksiyonu FTKF	
		0,001	0,0001	0,001	0,0001	0,001	0,0001
2	DBK	99,41	99,32	99,44	99,35	99,41	99,31
	Jİ	98,83	98,66	98,88	98,71	98,83	98,63
	GHF	0,26	0,47	0,35	0,60	0,56	0,67
	FTK	99,99	99,99	99,99	99,99	99,99	99,99
	FDK	86,38	82,81	86,04	82,01	83,61	80,64
4	DBK	99,43	99,32	99,41	99,34	99,38	99,21
	Jİ	98,80	98,65	98,83	98,68	98,77	98,44
	GHF	0,32	0,53	0,53	0,61	0,55	0,77
	FTK	99,99	99,99	99,99	99,99	99,99	99,99
	FDK	86,34	82,17	84,06	81,73	83,16	77,92


Klasik eğitim sürecinde, FDKF kayıp fonksiyonu ile 0,001 öğrenme oranı ve 2 yığın boyutunun birlikte kullanıldığı senaryo; ortalama DBK, Jİ ve FTK metrikleri açısından en yüksek performansı elde eden kombinasyon olmuştur.

Buna karşılık, en düşük GHF değeri; DKF kullanılarak, 0,001 ÖO ve 2 YB ile gerçekleştirilen eğitimde elde edilmiştir.

Elde edilen bulgular, tüm model konfigürasyonlarında 0,001 ÖO değerinin 0,0001'e kıyasla tutarlı biçimde daha iyi sonuçlar sağladığını göstermektedir.

Her bir test verisi için, nesne sınırlarının doğruluğunu değerlendirmek amacıyla OSYM, HM ve HM95 metrikleri hesaplanmıştır.

Şekil 4.2, klasik eğitim süreci kapsamında $YB = 2$, $\ddot{O}O = 0,001$ ve FDKF kullanılarak eğitilen en iyi modelin test verilerine ait HM, HM95 ve OSYM ölçümlerini göstermektedir. Grafiklerde veri bazlı dağılımlar sunulmuş olup, ilgili metriklerin genel performansı ortalama değerler (HM: 61,14 mm; HM95: 6,70 mm; OSYM: 1,11 mm) ve standart sapmalar (HM: 22,53 mm; HM95: 12,59 mm; OSYM: 1,36 mm) ilgili metriklerin istatistiksel özelliklerini ortaya koymaktadır.



Şekil 4.2. Abdomen segmentasyonunda klasik eğitim sürecinde en iyi modelin test verilerine ait metriklerinin dağılımı: (a) HM, (b) HM95 ve (c) OSYM

Veri seti üzerinde yapılan ayrıntılı analiz sonucunda, Veri20 olarak etiketlenen örneğin en düşük performansı sergilediği belirlenmiştir. Bu veride HM değeri 100 mm, OSYM 4,88 mm ve HM95 44,58 mm olarak hesaplanmıştır. Bu yüksek hata değerleri, söz konusu örnekte modelin sınır tahmininde belirgin sapmalar yaşadığını göstermektedir.

Buna karşılık, Veri13 örneği en başarılı sonuçları ortaya koymuştur. Bu test verisinde OSYM değeri yalnızca 0,37 mm, HM95 değeri ise 2,11 mm olarak elde edilmiş, dolayısıyla modelin sınır doğruluğu yüksek düzeyde gerçekleşmiştir. Ayrıca HM açısından en düşük değer 33,98 mm ile Veri14 örneğinde gözlenmiştir. Bu sonuç, modelin birçok test verisinde oldukça hassas ve istikrarlı segmentasyonlar üretebildiğini ortaya koymaktadır.

Genel olarak, tüm test verileri üzerinden ortalama OSYM=1,11 mm, HM=61,14 mm ve HM95=6,70 mm değerleri elde edilmiştir. Bu bulgular, klasik eğitim süreciyle eğitilen modelin, abdomen segmentasyonunda organ sınırlarını büyük oranda doğru biçimde tahmin edebildiğini, ancak bazı uç verilerde (örneğin Veri 20) performansın düşebildiğini göstermektedir.

Karın bölgesinin sınırlarının doğru şekilde belirlenmesi, İA tanımı açısından kritik bir kriterdir. Bu nedenle, modelin karın içindeki yapıları tam olarak tespit edememesi, genel değerlendirme açısından daha az önem arz etmektedir. Bu çalışmada öncelikli odak noktası, İA sınırlarının doğru şekilde çizilmesi olduğundan, modelin iç detaylardaki küçük sapmalarından ziyade sınır belirleme doğruluğu esas alınmıştır.

4.2.2. Çapraz doğrulama ile eğitime ait nicel sonuçlar

Abdomen segmentasyonu için gerçekleştirilen k-katlı çapraz doğrulama (k-fold cross-validation, k katlı ÇD) sürecinde, yöntemin model genellenebilirliği üzerindeki etkisi değerlendirilmiştir. Bu yöntemde, eğitim ve doğrulama veri kümeleri birleştirilmiş ve belirlenen k değeri doğrultusunda veri seti eşit büyüklükte k alt kümesine (fold) ayrılmıştır. Her yinelemede bu alt kümelerden biri test verisi olarak kullanılırken, kalan $k-1$ alt küme eğitim için ayrılmıştır. Böylece her örnek hem eğitim hem de test aşamalarında bir kez kullanılarak modelin aşırı uyum (overfitting) eğilimine karşı daha dengeli bir biçimde değerlendirilmesi sağlanmıştır.

Modelin farklı katlama sayılarındaki kararlılığını incelemek amacıyla $k=5$ ve $k=10$ olmak üzere iki farklı çapraz doğrulama stratejisi uygulanmıştır. Klasik eğitim

aşamasında yapılan analizler sonucunda, öğrenme oranı (ÖO)=0,001 değerinin daha iyi sonuçlar verdiği gözlemlenmiştir. Bu doğrultuda, çapraz doğrulama sürecinde de aynı öğrenme oranı kullanılmış ve 3B U-Net mimarisi, DKF, FDKF ve FTKF kayıp fonksiyonlarıyla eğitilmiştir.

Her iki katlama stratejisi için ayrıca iki farklı YB denenmiş ve böylece toplam 12 farklı model eğitilmiştir. Bu deneysel yapı hem katlama sayısının hem de farklı kayıp fonksiyonlarının model başarımına olan etkilerini sistematik biçimde değerlendirmeyi mümkün kılmıştır.

Çizelge 4.6, ÇD süreci sonucunda elde edilen ortalama nicel test sonuçlarını özetlemekte ve farklı katlama stratejilerinin modelin genelleme yeteneği üzerindeki etkisini karşılaştırmalı olarak sunmaktadır.

Çizelge 4.6. Abdomen segmentasyonunda çapraz doğrulama (ÇD) sürecinden elde edilen ortalama nicel test sonuçları

Yığın Boyutu	Metrikler [%]	Kayıp Fonksiyonu DKF		Kayıp Fonksiyonu FDKF		Kayıp Fonksiyonu FTKF	
		Katlama Sayısı (k)					
		5	10	5	10	5	10
2	DBK	99,51	99,48	99,43	99,55	99,40	99,43
	Jİ	99,03	98,96	98,87	99,11	98,80	98,86
	GHF	0,29	0,17	0,34	0,43	0,47	0,21
	FTK	99,99	99,99	99,99	99,99	99,99	99,99
	FDK	88,09	88,51	86,09	87,47	84,18	87,14
4	DBK	99,45	99,71	99,49	99,55	99,40	99,41
	Jİ	98,91	99,42	98,99	99,10	98,80	98,84
	GHF	-0,15	0,22	0,55	0,37	0,25	0,41
	FTK	99,99	99,99	99,99	99,99	99,99	99,99
	FDK	91,03	92,45	85,31	87,97	86,24	85,05

Modellerin değerlendirme sürecinde, farklı senaryolara bağlı olarak geniş bir sonuç aralığı gözlemlenmiştir. DKF ile eğitilen modeller, özellikle başarılı performans sergilemiş; YB=4 ve k=10 konfigürasyonunda, DBK için %99,71 ve Jİ için %99,42 gibi oldukça yüksek doğruluk değerlerine ulaşılmıştır. Bu bulgular, model tahmininin, referans ile yüksek oranda örtüştüğünü ve güçlü bir segmentasyon başarısı sergilediğini göstermektedir.

Buna karşılık, FDK değerleri, özellikle YB=2 ve k=5 olan yapılandırmalarda daha düşük performans göstermiştir. Bu durumda, özellikle FTKF ile eğitilen modelde, FDK

değerleri %84,18'e kadar gerilemiştir. Bu durum, belirli konfigürasyonlarda modelin sınırlı genelleme kapasitesi sergileyebileceğini ortaya koymaktadır.


En başarılı model yapılandırması (YB=4, DKF ve k=10) kullanılarak, test verilerinin her biri için mesafeye dayalı metrikler hesaplanmıştır. Böylece modelin sınır belirleme doğruluğu ayrıntılı biçimde incelenmiş ve performans değerlendirmesi, yalnızca piksel düzeyindeki örtüşme ölçütleriyle sınırlı kalmayıp yapısal sınır hassasiyetini de kapsayacak şekilde genişletilmiştir.

Şekil 4.3, Abdomen segmentasyonunda ÇD ile eğitim sürecinde en iyi modelin test verilerine ait HM, HM95 ve OSYM ölçümlerinin dağılımını göstermektedir. Veri bazlı sonuçlara ek olarak, ortalama değerler (OSYM: 0,91 mm; HM: 58,58 mm; HM95: 6,33 mm) ile standart sapmalar (OSYM: 1,26 mm; HM: 22,10 mm; HM95: 12,11 mm) da ilgili metriklerin istatistiksel özelliklerini ortaya koymaktadır.

Test veri seti üzerinde yapılan analizde, en düşük performansın Veri20'de ortaya çıktığı görülmüştür. Bu veride model, HM için 100,12 mm, OSYM için 4,70 mm ve HM95 için 42,81 mm değerleri üretmiştir.

Buna karşılık, en iyi sonuçlar Veri13'te elde edilmiştir; bu veride OSYM değeri yalnızca 0,37 mm, HM95 değeri ise 2,12 mm ile en düşük seviyede gerçekleşmiştir. Öte yandan, en düşük HM değeri 30,65 mm olup bu değer Veri35'te gözlenmiştir.

Klasik eğitim ve ÇD yaklaşımlarının en iyi modellerinin karşılaştırılması, modelin genelleme başarısı üzerindeki etkileri açıkça ortaya koymaktadır. Ortalama değerler karşılaştırıldığında, ÇD modeli hem OSYM (1,11 mm → 0,91 mm) hem de HM (61,14 mm → 58,58 mm) metriklerinde belirgin bir iyileşme sağlamıştır. Benzer biçimde HM95 değeri de 6,70 mm'den 6,33 mm'ye gerilemiştir. Bu sonuçlar, çapraz doğrulama stratejisinin modelin farklı veri alt kümelerinde daha istikrarlı öğrenme gerçekleştirmesine olanak tanıdığını ve sınır belirleme doğruluğunu artırdığını göstermektedir.



Şekil 4.3. Abdomen segmentasyonunda ÇD ile eğitim sürecinde en iyi modelin test verilerine ait mesafeye dayalı metriklerin dağılımı: (a) HM, (b) HM95 ve (c) OSYM

Ayrıca, standart sapma değerlerindeki düşüş (OSYM: 1,36 → 1,26, HM: 22,53 → 22,10, HM95: 12,59 → 12,11), ÇD yaklaşımının model varyansını azalttığını ve sonuçların daha kararlı hale geldiğini desteklemektedir. Bu bulgular, k-katlı çapraz doğrulama yönteminin, modelin genelleme kabiliyetini artıran ve aşırı öğrenmeyi azaltan etkili bir strateji olduğunu ortaya koymaktadır.

4.2.3. İA kırpma işleminden elde edilen nicel sonuçlar

Bu bölümde, abdomen segmentasyonunda klasik eğitim süreciyle elde edilen en iyi model, ÇD yöntemiyle eğitilen en iyi model ve en düşük performans gösteren model olmak üzere üç farklı model kullanılarak elde edilen İA nicel sonuçları incelenmiştir. Klasik eğitim süreci kapsamında en başarılı model, $YB=2$, $\ddot{O}O=0,001$ ve FDKF kullanılarak elde edilmiştir. Buna karşılık, ÇD yöntemiyle en iyi performans, $YB=4$, $\ddot{O}O=0,001$ ve DKF kullanılarak eğitilen modelde gözlemlenmiştir. En düşük performansa sahip model ise, klasik eğitim sürecinde $YB=4$, $\ddot{O}O=0,0001$ ve FTKF kullanılarak eğitilmiştir.

Segmentasyon süreci tamamlandıktan sonra, her bir test verisi için hem en iyi hem de en kötü model kullanılarak tahminler elde edilmiştir. Daha sonra, BBA yöntemiyle karın bölgesine ait İA belirlenmiştir. İzleyen adımda, belirlenen İA doğrusal olarak yukarı ölçeklenmiş (lineer olarak büyütülmüş) ve orijinal görüntüden çıkarılmıştır.

Çizelge 4.7, segmentasyon işlemi sonrasında BBA yöntemi kullanılarak elde edilen karın bölgesi İA'larına ait kırpılmış test görüntülerinin uzamsal boyutlarını göstermektedir.

Klasik eğitim yöntemiyle elde edilen en iyi modelin, test veri seti genelinde ortalama %33,34 oranında piksel azaltımı sağladığı gözlemlenmiştir. Öte yandan, ÇD yöntemiyle elde edilen en iyi modelde bu oran %32,79 olarak gerçekleşmiştir. Çalışmada en düşük performansı sergileyen model ise test veri seti genelinde %33,12'lik bir piksel azaltımı sağlamıştır.

Segmentasyon sonuçlarındaki farklılıklara rağmen hem en iyi hem de en kötü modellerin karın bölgesi İA tespiti açısından tatmin edici sonuçlar verdiği görülmüştür. Ancak, klasik eğitimde kullanılan en iyi model ve en kötü model, bazı küçük anatomik detayları atlamıştır.

Kırpılan görüntülerin boyutlarının test verileri arasında farklılık göstermesi hem anatomik çeşitlilikten hem de tahmin edilen sınırlayıcı kutuların boyutlarındaki değişkenlikten kaynaklanmaktadır. Bu durumu dengelemek amacıyla, detaylı segmentasyon işleminden önce kırpılan görüntülerin sabit bir boyuta dönüştürülmesi önerilmektedir.

Çizelge 4.7. Abdomen segmentasyonunda farklı segmentasyon modelleriyle elde edilen kırpılmış görüntü boyutlarının test verilerine göre sunulması

Veri	Görüntü Boyutu	Klasik Eğitimde En İyi Model	ÇD'de En İyi Model	En Kötü Model
		Kırpılmış Görüntü Boyutu	Kırpılmış Görüntü Boyutu	Kırpılmış Görüntü Boyutu
5	(512,512, 61)	(478, 386, 61)	(478, 386, 61)	(478, 386, 61)
7	(512,512,77)	(450, 278, 77)	(450, 278, 77)	(450, 278, 77)
8	(512,512,50)	(486, 378, 50)	(506, 378, 50)	(486, 378, 50)
13	(512,512, 75)	(486, 382, 75)	(486, 382, 75)	(486, 382, 75)
14	(512,512, 32)	(470, 374, 32)	(470, 374, 32)	(470, 374, 32)
18	(512,512, 670)	(507, 374, 670)	(507, 374, 670)	(507, 374, 670)
20	(512,512, 68)	(422, 314, 68)	(422, 314, 68)	(422, 314, 68)
26	(512,512, 80)	(490, 386, 80)	(490, 386, 80)	(490, 382, 80)
33	(512, 512, 51)	(462, 390, 51)	(462, 390, 51)	(462, 390, 51)
35	(512, 512, 34)	(495, 410, 34)	(495, 410, 34)	(495, 410, 34)
37	(512, 512, 113)	(490, 370, 113)	(490, 370, 113)	(490, 370, 113)

Bu işlem, giriş verilerinin işlenmesini basitleştirir, mevcut derin öğrenme mimarileriyle uyumluluğu artırır ve hesaplama maliyetini düşürür. Ancak, kırpma işleminden önce yapılan yeniden boyutlandırma, önemli detayların kaybına yol açabilir. Buna karşın, kırpma sonrası yeniden boyutlandırma, İA zaten izole edildiği için bu kayıpları en aza indirir.

Alternatif olarak, görüntü boyutlarını birleştirmek için sıfır dolgusu (zero-padding) yöntemi de kullanılabilir. Bu yöntem, görüntünün orijinal mekânsal oranlarını koruyarak bozulmayı önler. Ancak, görüntü etrafında yapay siyah kenarlıklar oluşturduğu için, dikkatli yönetilmediği takdirde modelin öğrenme sürecini olumsuz etkileyebilir. Ayrıca, özellikle küçük boyutlu kırpılmış görüntülerde hesaplama yükünü artırma riski taşımaktadır.

4.2.4. Görsel sonuçlar











Bu bölümde, çalışmada elde edilen en iyi ve en kötü modellerin görsel çıktılarına yer verilmesi amaçlanmıştır. Seçilen bazı test verileri için, en iyi ve en kötü modellerle elde edilen segmentasyon sonuçları görselleştirilmiştir. Çizelge 4.8, klasik eğitim yöntemiyle eğitilen en iyi modelin görsel çıktılarının örneklerini sunarken; Çizelge 4.9, çapraz doğrulama yöntemiyle elde edilen en iyi modelin çıktılarının görsel temsillerini

içermektedir. Çizelge 4.10 ise çalışmada elde edilen en kötü modelin (klasik eğitim, FTKF, YB=4 ve $\ddot{O}O=0,0001$) segmentasyon çıktılarının görselleştirilmiş halini göstermektedir.










Görseller incelendiğinde, en kötü model dahil olmak üzere tüm modellerin çıktıları ile referans görüntü arasında belirgin bir uyum gözlemlenmiştir. Ayrıca, tüm modellerin DBK değerleri genel olarak oldukça yüksek seviyelerdedir. Bununla birlikte, yüksek DBK değerlerinin ötesinde, karın bölgesi sınırlarının doğru şekilde çizilmesi, model başarımı açısından kritik öneme sahiptir. Özellikle klasik eğitim yöntemiyle elde edilen sonuçlar incelendiğinde, Veri8, Veri13 ve Veri20 için DBK değerleri sırasıyla 0,9965, 0,9937 ve 0,9918 olarak elde edilmiştir. Çapraz doğrulama yöntemiyle elde edilen en iyi modelde ise bu değerler biraz daha yüksek olup, sırasıyla 0,9956, 0,9943 ve 0,9930 şeklindedir. Buna karşılık, en kötü modelin aynı veriler için DBK değerleri gözle görülür şekilde daha düşüktür: 0,9931, 0,9919 ve 0,9913. Görselleştirilen örnekler rastgele seçilmiştir.

Çizelge 4.10, en kötü modelin (klasik eğitim, FTKF, YB=4 ve $\ddot{O}O=0,0001$) görsel çıktılarının örneklerini göstermektedir. 3B sonuçların analizinde, bu modelin çıktıları ile hedef görüntüler arasındaki benzerliğin, diğer iki en iyi modele kıyasla daha düşük olduğu görülmüştür.










Çizelge 4.8. Abdomen segmentasyonunda klasik eğitim yöntemiyle elde edilen en iyi modelden rastgele seçilen verilerin görsel çıktıları

Veri	BT Görüntüsü	Referans Görüntü	Tahmin Görüntüsü	Kesişim
8				 DBK = 0,9965
13				 DBK = 0,9937
20				 DBK = 0,9918

Çizelge 4.9. Abdomen segmentasyonunda ÇD yöntemiyle elde edilen en iyi modelden rastgele seçilen verilerin görsel çıktıları













Veri	BT Görüntüsü	Referans Görüntü	Tahmin Görüntüsü	Kesişim
8				 DBK=0,9956
13				 DBK=0,9943
20				 DBK= 0,9930

Çizelge 4.10. Abdomen segmentasyonunda en kötü modelden elde edilen rastgele seçilen verilerin görsel çıktıları

Veri	BT Görüntüsü	Referans Görüntü	Tahmin Görüntüsü	Kesişim
8				 DBK=0,9931
13				 DBK=0,9919
20				 DBK=0,9913

Tüm modeller için 3B segmentasyon işlemleri tamamlandıktan sonra, seçilen veriler üzerinde karın bölgesine ait İA'lar kesilmiştir. Çizelge 4.11'de, bu test verilerine ait orijinal görüntüler ile bunlara karşılık gelen 3B kırpılmış hacimler ve her birine ait piksel azaltım oranı (AO) değerleri sunulmaktadır. Bu çizelge, İA çıkarma sürecinin hacimsel düzeydeki etkisini nicel olarak ortaya koymakta ve kırpma işleminin veri boyutundaki azaltım düzeyini karşılaştırmalı biçimde göstermektedir.

Çizelge 4.11. Abdomen segmentasyonunda rasgele seçilen test verilerine ait orijinal ve kırpılmış görüntüler

Veri	Orijinal Görüntü	Kırpılmış Görüntü		
		Klasik eğitim en iyi	ÇD En iyi	Klasik eğitim en kötü
7	 (512,512,77)	 (450, 278, 77) AO=%52,28	 (450, 278, 77) AO=%52,28	 (450, 278, 77) AO=%52,28
8	 (512,512,50)	 (486, 378, 50) AO=%29,92	 (506, 378, 50) AO=%27,04	 (486, 378, 50) AO=%29,92
20	 (512,512, 68)	 (422, 314, 68) AO=%49,45	 (422, 314, 68) AO=%49,45	 (422, 314, 68) AO=%49,45
26	 (512,512,80)	 (490, 386, 80) AO=%27,85	 (490, 386, 80) AO=%27,85	 (490, 382, 80) AO=%28,60

4.3. Böbrek Kaba Segmentasyon Sonuçları

Bu bölümde, böbrek bölgelerinin kaba segmentasyonu için gerçekleştirilen deneysel çalışmaların sonuçları sunulmaktadır. Kaba segmentasyon aşamasında, böbrek bölgelerinin belirlenmesi amacıyla iki farklı yaklaşım uygulanmıştır. Birinci yaklaşım,

Bölüm 3.3.2.1’de; ikinci yaklaşım ise Bölüm 3.3.2.2’de ayrıntılı olarak açıklanmıştır. Her iki yöntemin deneysel değerlendirmeleri, doğruluk ölçütleri ve görsel çıktıları aşağıdaki alt başlıklar hâlinde sunulmuştur.

Birinci yaklaşımda, KiTS23 veri seti eğitim için, FLARE22 veri seti ise test amacıyla kullanılmıştır. İkinci yaklaşımda ise, KiTS23’e kıyasla daha küçük bir veri seti olan KiTS19’un büyük kısmı eğitim için, test aşamasında ise hem KiTS19’un kalan örnekleri hem de FLARE22 veri seti kullanılmıştır. Bu dağılım, her iki yaklaşımın farklı veri boyutları ve çeşitliliğine dayalı performansını karşılaştırmalı olarak incelemeye olanak sağlamaktadır.

4.3.1. Birinci yaklaşım sonuçları

Birinci yaklaşımda, her iki böbrek hacminin segmentasyonu için 3B U-Net tabanlı bir derin öğrenme modeli geliştirilmiştir. Model, 40 epok boyunca eğitilmiştir (ayrıntılar Bölüm 3.3.2.1’de verilmiştir). Eğitim sürecinde YB=2 olarak belirlenmiş, kayıp fonksiyonu olarak DKF ve FKF’nın birleşiminden oluşan hibrit bir yapı kullanılmıştır. Bu tercih hem sınıf dengesizliğini azaltmak hem de sınır bölgelerindeki segmentasyon hatalarını en aza indirmek amacı taşımaktadır.

Modelin parametrelerinin güncellenmesinde, $\text{ÖO}=0,0001$ olarak ayarlanmış ve Adam optimizasyon algoritması tercih edilmiştir. Ayrıca, modelin genelleme kabiliyetini ve güvenilirliğini artırmak amacıyla 5 kat ÇD uygulanmıştır.

Deneysel bulgular Çizelge 4.12’de özetlenmektedir. Önerilen 3B U-Net tabanlı model, eğitim kümesinde %94,96 DBK ve test kümesinde %88,51 DBK değeri elde etmiştir. Jİ değerleri sırasıyla eğitim kümesi için %90,53 ve test kümesi için %80,01 olarak hesaplanmıştır. Ayrıca, GHF değerleri eğitim kümesinde %2,54, test kümesinde ise %10,84 olarak elde edilmiştir. Elde edilen sonuçlar, modelin eğitim verisi üzerinde yüksek segmentasyon doğruluğu sağladığını, ancak test kümesinde gözlemlenen göreceli performans düşüşünün modelin genelleme kapasitesinde belirli sınırlılıklara işaret ettiğini göstermektedir. Bununla birlikte, 3B U-Net mimarisinin hacimsel uzamsal ilişkileri etkin biçimde öğrenerek böbrek bölgelerinin kaba konumlarını başarılı şekilde belirleyebildiği sonucuna varılmaktadır.

Mesafeye dayalı performans ölçütleri incelendiğinde, model eğitim kümesinde sırasıyla 23,40 mm HM, 9,89 mm HM95 ve 2,8 mm OSYM değerleri elde etmiştir. Test kümesinde ise bu metrikler sırasıyla 37,69 mm HM, 24,66 mm HM95 ve 14,14 mm MSD

olarak hesaplanmıştır. Özellikle test verisinde gözlemlenen mesafeye dayalı metriklerdeki sapmalar, sınır bölgelerindeki segmentasyon doğruluğunun düşme eğilimini yansıtmaktadır.

Bu bulgular, modelin böbrek hacimlerini genel olarak yüksek doğrulukla yüksek doğrulukla saptadığını, ancak test kümesinde özellikle sınır bölgelerinde mesafeye dayalı metriklerde belirgin sapmaların görüldüğünü ortaya koymaktadır. Bu durum, önerilen yöntemin klinik uygulamalarda kullanılabilir potansiyele sahip olduğunu, ancak genelleme kapasitesini artırmaya yönelik ek optimizasyon ve ince ayar çalışmalarının gerekli olabileceğini göstermektedir.

Çizelge 4.12. Böbrek kaba segmentasyon için eğitilen 3B U-Net modelinin segmentasyon sonuçları

Veri Seti	[%] DBK	[%] Jİ	[%] GHF	HM [mm]	HM95 [mm]	OSYM [mm]
Eğitim (Kits23)	94,96±2,84	90,53±4,68	2,54±7,12	23,40±13,70	9,89±5,15	2,80±1,10
Test (FLARE22)	88,50±7,45	80,10±10,78	10,84±2,48	37,69±29,88	14,08±17,01	3,83±4,38

4.3.1.1. İA kırpma işleminden elde edilen nicel sonuçlar

Kaba segmentasyon sürecinin tamamlanmasının ardından, eğitim veri kümesindeki örneklerin ağ tahminleri üzerinde 2B BBA algoritması uygulanmış ve bu işlem sonucunda elde edilen uzamsal pencere konumları ile hacim boyutları ayrıntılı biçimde analiz edilmiştir. Çizelge 4.13, sol ve sağ böbrekler için İA pencere boyutlarının maksimum, minimum, ortalama ve standart sapma değerlerini sunmaktadır. Bu metrikler, İA boyutlarındaki değişkenlikleri nicel olarak değerlendirmeye imkân tanımakta ve her iki böbrek için segmente edilen bölgelerin uzamsal aralığını ve tutarlılığını ortaya koymaktadır.

Elde edilen veriler, İA kırpma işleminin hem sol hem de sağ böbrek için kararlı ve tekrarlanabilir bir boyutlandırma sağladığını göstermektedir. Aynı zamanda, pencere ve hacim boyutlarındaki varyasyonların değerlendirilmesi, sonraki aşamalarda uygulanacak ince segmentasyon ve istatistiksel analizler için güvenilir bir temel oluşturmaktadır.

Çizelge 4.13. Böbrek kaba segmentasyonu sonucunda Kits23 veri setinde kırpılan pencere boyutlarının istatistiksel verileri

Böbrek Konumu	Min-Maks Yükseklik	Min-Maks Genişlik	Min-Maks Derinlik	Ort- Std Yükseklik	Ort- Std Genişlik	Ort- Std Derinlik
Sol	54-141	85-141	50-112	108,59±18,09	111,97±13,54	80,78±15,45
Sağ	70-217	80-151	57-110	113,88±23,94	106,24±15,45	78,02±14,74

4.3.2. İkinci yaklaşım sonuçları

Bu bölümde, önerilen yöntemin kaba böbrek segmentasyonu için elde edilen sonuçları sunulmaktadır. Bu amaçla, böbrek etiketleriyle birlikte karın bölgesine ait BT hacimlerinden yararlanılarak üç farklı yama tabanlı 3B derin öğrenme mimarisi — U-Net, ResUNet ve AttUNet — eğitilmiştir. Sol ve sağ böbreklerin segmentasyonu, tek bir model tarafından ortak olarak gerçekleştirilmiştir. Eğitim süreci, Bölüm 3.3.2.2’de ayrıntılı olarak açıklandığı üzere 25 epok boyunca yürütülmüştür.

Eğitim aşamasında $YB=1$ olarak belirlenmiş ve sınıf dengesizliğini gidermek amacıyla DKF ve FKF bileşenlerinden oluşan hibrit bir kayıp fonksiyonu kullanılmıştır. YB ’nin minimum değer tercih edilmesinin nedeni, yüksek çözünürlüklü hacimsel tıbbi verilerin işlenmesi sırasında ortaya çıkan yüksek bellek gereksinimleridir. Tam 3B BT hacimleri, GPU belleği üzerinde ciddi bir hesaplama yükü oluşturmakta ve bu durum genellikle daha küçük yığın boyutlarının kullanılmasını zorunlu kılmaktadır. Literatürde de benzer yaklaşımlar görülmektedir; örneğin, Isensee ve ark. (2021) çalışmalarında $128 \times 128 \times 128$ yama boyutu ile $YB=2$ kullanmışlardır. Çiçek ve ark.(2016) ise modellerini $YB=1$ veya 2 olacak şekilde başarıyla eğitmiştir.

Eğitim işlemleri, 0,0001 öğrenme oranına sahip Adam optimizasyon algoritması ile yürütülmüştür. Bu düşük öğrenme oranı, kararlı bir yakınsama ile etkili öğrenme arasında denge kurmak amacıyla tercih edilmiştir. Nitekim benzer optimizasyon stratejileri uygulayan önceki çalışmalar da (Isensee ve ark., 2021; Liu ve ark., 2021), 3B U-Net mimarilerini karşılaştırılabilir koşullar altında optimize etmiştir. Modelin genellenebilirliğini artırmak ve aşırı öğrenmeyi önlemek amacıyla 5 kat ÇD yöntemi uygulanmıştır.

Modelin eğitimi kapsamında, KiTS19 veri setinden toplam 167 BT görüntüsü kullanılmıştır. Test aşamasında ise, modelin farklı veri kümeleri üzerindeki genelleme kabiliyetini değerlendirmek amacıyla KiTS19 veri setinden 42 daha önce görülmemiş veri ve buna ek olarak FLARE22 veri setinden 50 test verisi olarak seçilmiştir. Bu şekilde, modelin hem aynı veri seti içinde hem de veri dağılımı farklı bir dış küme üzerinde performansının kapsamlı biçimde değerlendirilmesi hedeflenmiştir.

Çizelge 4.14’te sunulan sonuçlar, önerilen yöntemin 3. adımında (Şekil 3.15) elde edilen $128 \times 128 \times 128$ boyutundaki tahmin hacimleri üzerinde doğrudan gerçekleştirilen böbrek segmentasyon performansı değerlendirmesine karşılık gelmektedir. Bu değerlendirme düzeninde hem tahmin edilen hem de referans hacimler aynı aşağı

ölçeklenmiş çözünürlükte tutulmuş ve böylece doğrudan vokselle düzeyinde karşılaştırma yapılabilmiştir. Buna karşılık, Çizelge 4.15'te raporlanan sonuçlar, tahmin görüntülerinin orijinal 512×512 düzlemsel çözünürlüğe yeniden ölçeklenmesinden (upsampling) sonra elde edilen performansı yansıtmaktadır. Bu yeniden ölçekleme adımı, segmentasyon kalitesinin görsel olarak incelenebilmesi ve verilerin özgün uzamsal bağlamında değerlendirilebilmesi amacıyla uygulanmıştır. Dolayısıyla, Çizelge 4.15, segmentasyon performansına ilişkin daha gerçekçi ancak hataya açık bir değerlendirme sunmaktadır.

Çizelge 4.14. Aşağı ölçeklenmiş çözünürlükte böbrek kaba segmentasyon sonuçları (128×128×128)

Veri	Model	%DBK	%Jİ	%GHF
KiTS19 Test	3B U-Net	93,44±6,46	88,30±10,15	5,60±16,83
	3B ResUNet	91,16±11,74	85,43±15,66	16,69±49,20
	3B AttUNet	93,28±6,26	87,98±10,01	4,86±14,07
FLARE22 Test	3B U-Net	82,06±13,78	71,77±18,76	15,76±33,88
	3B ResUNet	84,68±12,64	75,23±16,62	8,95±60,57
	3B AttUNet	76,19±15,99	64,16±20,42	13,50±64,73

Çizelge 4.14'te görüldüğü üzere, aşağı örneklenmiş çözünürlükte yapılan değerlendirme genellikle daha yüksek DBK ve daha düşük GHF değerleri üretmiştir; bu durum özellikle KiTS19 veri seti için belirgindir. Değerlendirilen modeller arasında, 3B U-Net ve 3B AttUNet en yüksek performansa ulaşmış, DBK değerleri %93'ün üzerine çıkarken, GHF değerleri %6'nın altında kalmıştır. Bu sonuçlar, yüksek uzamsal uyum ve doğru hacim tahminini göstermektedir.

Çizelge 4.15'te sunulan sonuçlar, yukarı ölçekleme sonrasında elde edilen segmentasyon performansını göstermektedir. Ölçekleme işleminden kaynaklanan küçük geometrik sapmalar, metriklerde sınırlı düzeyde bir düşüşe yol açmış olsa da 3B U-Net ve AttUNet modelleri, KiTS19 veri seti üzerinde yüksek doğruluklarını büyük ölçüde korumuştur. Her iki model de yaklaşık %91 DBK ve %5'in altında GHF değerleri elde etmiştir.

Çizelge 4.15. Orijinal çözünürlükte böbrek kaba segmentasyon sonuçları (512×512)

Veri	Model	%DBK	%Jİ	%GHF	HM [mm]	HM95 [mm]	OSYM [mm]
KiTS19 Test	3B U-Net	91,56±6,01	88,30±10,15	4,64±16,19	51,33±60,70	10,76±20,91	2,16±3,57
	3B ResUNet	89,49±11,07	82,41±14,76	15,27±46,83	56,17±63,40	11,97±23,11	2,57±4,32
	3B AttUNet	91,48±5,80	84,78±9,00	3,89±13,26	60,64±82,04	10,53±21,21	2,2±3,78
FLARE22 Test	3B U-Net	80,37±13,42	69,16±17,75	15,45±34,03	65,56±28,26	35,56±27,58	7,25±6,06
	3B ResUNet	82,83±12,35	72,35±15,88	8,7±58,87	64,20±34,87	21,82±22,51	4,61±4,65
	3B AttUNet	74,39±15,65	61,63±19,40	13,00±66,26	81,86±26,43	44,78±31,62	9,85±7,93

FLARE22 veri seti üzerinde tüm modellerin performansında anlamlı bir düşüş gözlenmiştir. Bu düşüş, veri setinin anatomik varyasyonlar açısından daha geniş dağılıma ve görüntü heterojenliğine sahip olmasından kaynaklanmaktadır. Ayrıca, eğitim sürecinde FLARE22 verilerinin hiç kullanılmamış olması, modellerin genelleme yeteneğini sınırlandırmıştır. Bununla birlikte, 3B ResUNet modeli, her iki çözünürlükte de daha kararlı ve sınır doğruluğu yüksek sonuçlar üretmiş; özellikle daha düşük GHF, HM95 ve OSYM değerleriyle dikkat çekmiştir. Bu bulgular, 3B ResUNet'in anatomik sınırların konumunu daha tutarlı biçimde belirleme kapasitesine sahip olduğunu göstermekte ve karmaşık veri koşullarında genel dayanıklılığının diğer modellere göre daha yüksek olabileceğini ortaya koymaktadır. Dolayısıyla, 3B ResUNet'in genel doğruluk açısından 3B U-Net'in gerisinde kalmasına rağmen, sınır belirleme kararlılığı bakımından klinik açıdan daha güvenilir çıktılar sunduğu söylenebilir.

4.3.2.1. İA kırpma işleminden elde edilen nicel sonuçlar

Kaba segmentasyon sürecinin ardından, test veri seti üzerinde 3B BBA uygulandıktan sonra elde edilen uzamsal pencere ve hacim boyutları detaylı olarak incelenmiştir. Çizelge 4.16, sol ve sağ böbrekler için İA pencere boyutlarının maksimum, minimum, ortalama ve standart sapma değerlerini sunmaktadır.

Pencere ve hacim boyutlarındaki değişkenliğin analizi, sonraki aşamalarda gerçekleştirilecek ince segmentasyon ve istatistiksel değerlendirmeler için sağlam bir ön işleme temeli oluşturmaktadır.

Çizelge 4.16. Böbrek kaba segmentasyonunda kırılan pencere boyutlarının istatistiksel verileri

Veri Seti	Böbrek Konumu	Min - Maks Yükseklik	Min-Maks Genişlik	Min-Maks Derinlik	Ort- Std Yükseklik	Ort- Std Genişlik	Ort- Std Derinlik
KiTS19	Sol	67-215	74-206	26-356	108,50±26,34	108,19±21,73	89,61±75,70
	Sağ	64-210	65-179	22-302	110,17±23,20	100,20±18,90	71,90±68,61
FLARE22	Sol	67-121	67-123	31-58	91,84±13,24	94,12±13,37	48,20±5,79
	Sağ	62-135	70-132	29-64	97,56±15,11	90,58±13,15	47,68±6,37

4.4.Böbrek İnce Segmentasyon Sonuçları

Kaba segmentasyon aşamasında uygulanan iki farklı yöntemin ardından, elde edilen pencere boyutları analiz edilerek ortalama yükseklik, genişlik ve derinlik değerleri incelenmiştir. Birinci çalışmada sırasıyla sağ ve sol böbrek için en büyük değerler 114, 112 ve 81 olarak belirlenmiştir. İkinci çalışmada ise en büyük değerler 110, 108 ve 90 olarak elde edilmiştir. Model mimarisi 4 kodlayıcı ve 4 kod çözücü katmandan oluştuğundan, giriş boyutlarının 16'nın katı olması gerekmektedir. Bu nedenle, ince segmentasyon aşaması için en uygun hacim boyutu $128 \times 128 \times 96$ olarak seçilmiştir. Bu boyutlandırma, hesaplama maliyeti ile uzamsal çözünürlük arasında dengeli bir ilişki sağlayarak modelin hem verimliliğini hem de performans kararlılığını artırmaktadır. Ayrıca, kullanılan mimarinin dört kodlayıcı ve dört kod çözücü katmandan oluşması nedeniyle, giriş boyutlarının 16'nın katları şeklinde seçilmesi, ağ yapısının bütünlüğünü korumak ve her katmanda gerçekleştirilen ölçekleme işlemlerinin tam sayı boyutlarda uygulanabilmesini sağlamak açısından gereklidir.

İnce segmentasyon aşamasında gerçekleştirilen çalışmalar üç ana başlık altında ele alınmıştır:

1. Voksel tabanlı derin öğrenme yaklaşımlarından 3B U-Net ile böbrek segmentasyonu sonuçları (Kits23 eğitim, FLARE22 test),
2. Yama tabanlı 3B ağlarla ince segmentasyon sonuçları (Kits19 eğitim, FLARE22 ve Kits19 test),
3. Nokta tabanlı ağlarla ince segmentasyon sonuçları (Kits23 eğitim, FLARE22 test).

Kaba segmentasyonun birinci yönteminin uygulandığı deneysel düzenekte, ince segmentasyon aşamasında 3B U-Net ve nokta tabanlı ağlar kullanılmıştır. Buna karşılık, ikinci yöntemin uygulandığı senaryoda, yama tabanlı 3B ağlarla ince segmentasyon gerçekleştirilmiştir. Her iki yaklaşımda da kullanılan veri setleri, eğitim-test dağılımı ve veri çeşitliliği açısından farklılık göstermekte, bu da modellerin genelleme yeteneklerinin karşılaştırmalı olarak değerlendirilmesine olanak sağlamaktadır.

4.4.1. 3B U-Net ile böbrek segmentasyonu sonuçları

İnce segmentasyon aşamasında böbrek yapılarını daha hassas biçimde belirlemek üzere 3B U-Net mimarisi kullanılmıştır. Her bir böbreğe ait İA'lar çıkarıldıktan sonra

kırpılan hacimler $128 \times 128 \times 96$ voksel boyutuna yeniden örneklenmiş (gerektiğinde aşağı ya da yukarı örnekleme uygulanmıştır). Şekil 3.16’da şematik olarak sunulan iş akışına uygun biçimde, bölgeye özgü tahminler her bir kırpılmış hacim üzerinde bağımsız olarak üretilmiş (Adım 9) ve bu bölgesel tahminler tam hacim düzeyindeki sonuçlarla birleştirilerek nihai, kapsamlı segmentasyon çıktıları elde edilmiştir (Adım 11). Çizelge 4.17 ise, Şekil 3.16’nın 9. adımında her iki böbrek için ayrı ayrı elde edilen ince segmentasyon sonuçlarının nicel değerlendirme bulgularını özetlemekte olup KiTS23 (eğitim) ve FLARE22 (test) veri kümelerine ait performans metriklerini sunmaktadır.



















Çizelge 4.17. Her iki böbrek için 3B U-Net’in $128 \times 128 \times 96$ pencere boyutlarında elde edilen ince segmentasyon skorları

Veri Seti	Sol Böbrek			Sağ Böbrek		
	[%] DBK	[%] Jİ	[%] GHF	[%] DBK	[%] Jİ	[%] GHF
Eğitim (Kits23)	98,04	96,16	2,85	96,66	93,54	2,80
Test (FLARE22)	92,94	89,84	14,64	92,95	90,00	11,21
Test (FLARE22)-Filtreli	94,00	90,91	13,51	94,31	91,37	9,83

KiTS23 eğitim veri seti üzerinde gerçekleştirilen ince segmentasyon, her iki böbrek için de oldukça yüksek doğruluk değerleri sağlamış; DBK ve Jİ %96’nın üzerinde bulunmuştur. Ayrıca, düşük GHF değerleri, modelin anatomik yapıları yüksek hassasiyetle yakalayabildiğini göstermektedir. Buna karşın, FLARE22 test kümesinde performansta bir miktar azalma gözlenmiştir. Bu durum, özellikle artan GHF değerleriyle kendini göstermiş ve farklı veri kümelerindeki anatomik çeşitlilik ile görüntü heterojenliğinin hacimsel doğruluk üzerinde zorluklar oluşturduğunu düşündürmektedir. Öte yandan hem eğitim hem test kümelerinde DBK ve Jİ değerlerinin yüksek seyretmesi, modelin uzamsal segmentasyon başarımının güçlü ve kararlı olduğunu ortaya koymaktadır.

Anatomik tutarlılığı artırmak ve yanlış pozitif tahminleri azaltmak amacıyla, ince segmentasyon sonuçlarına ek olarak BBA tabanlı bir son işlem uygulanmıştır. Bu aşamada, 100 vokselden küçük izole bileşenler elenmiş, böylece yanlış pozitifler ortadan kaldırılmış ve sınır sürekliliği iyileştirilmiştir. Çizelge 4.17’de görüldüğü üzere, bu filtreleme işlemi özellikle GHF metriğinde belirgin iyileşmeler sağlamış ve yöntemin dayanıklılığını artırmıştır. Ayrıca Çizelge 4.18, bu iyileştirmenin görsel etkisini ortaya koymakta olup her iki böbrek için en iyi, ortalama ve en kötü senaryoların BBA tabanlı filtreleme öncesi ve sonrası karşılaştırmalarını sunmaktadır.


Çizelge 4.18. FLARE22 veri seti üzerinde 3B U-Net modeli tarafından üretilen en iyi, orta ve en kötü böbrek ince segmentasyon sonuçlarının görsel karşılaştırması

Böbrek Pozisyonu	Performans	Tahmin	Referans Görüntü	Filtreli Tahmin
Sol	En İyi Veri:38	 DBK=%96,92		 DBK=%96,92
	Orta Veri:50	 DBK=%92,93		 DBK=%93,98
	En Kötü Veri:18	 DBK=%78,54		 DBK=%82,74
Sağ	En İyi Veri:47	 DBK=%97,35		 DBK=%97,36
	Orta Veri:15	 DBK=%93,11		 DBK=%94,15
	En Kötü Veri:43	 DBK= %81,90		 DBK=%81,89

Şekil 4.4, Şekil 3.16'nın 11. adımında tanımlanan işlem hattına uygun olarak 3B U-Net mimarisinin böbrek ince segmentasyon performansını göstermekte ve FLARE22 veri seti üzerinde Durum-1 (ham segmentasyon) ile Durum-2 (filtrelenmiş segmentasyon) çıktılarından elde edilen genel performans ölçütlerini karşılaştırmalı biçimde sunmaktadır. Bu kapsamda Durum-1, herhangi bir son işlem adımı uygulanmadan elde edilen ham segmentasyon tahminini ifade ederken; Durum-2, Morfolojik Açma ve BBA yöntemlerinin uygulanmasıyla gürültüden arındırılmış, sınır sürekliliği iyileştirilmiş nihai segmentasyon sonucunu temsil etmektedir.

Morfolojik açma işlemi, segmentasyon maskesinde yer alan küçük ve izole gürültü bileşenlerini ortadan kaldırmak amacıyla önce erozyon, ardından genişletme (dilation) adımlarının uygulanmasıyla gerçekleştirilmektedir (Said ve ark., 2016). Bu işlem, ana anatomik yapıların korunmasını sağlarken küçük yapay artefaktların etkili biçimde elenmesine olanak tanımaktadır. Buna paralel olarak BBA yöntemi, maskede bulunan bağlı bileşenleri analiz ederek 100 vokselde küçük bölgeleri önemsiz artefaktlar olarak değerlendirmekte ve bu alanları elimine ederek segmentasyon hacminin anatomik bütünlüğünü korumaktadır.

Her iki filtreleme adımının birlikte uygulanması, böbrek segmentasyon çıktısının kalitesini belirgin biçimde artırmakta; gereksiz gürültü baskılanmakta, sınır sürekliliği iyileştirilmekte ve model tahminleri hem klinik açıdan daha güvenilir hem de anatomik açıdan daha gerçekçi bir görünüm kazanmaktadır.



Şekil 4.4. FLARE22 veri seti üzerinde Durum-1 (ham segmentasyon) ve Durum-2 (filtrelenmiş segmentasyon) için elde edilen ortalama performans değerlerinin standart sapmalarıyla birlikte çubuk grafik üzerinde karşılaştırmalı gösterimi (Kits23 Eğitim)

Şekil 4.4'te sunulan değerlendirme metrikleri arasında DBK, Jİ, GHF, HM, HM95 ve OSYM yer almakta olup, sonuçlar ortalama $\pm$ standart sapma biçiminde verilmiştir. Tüm metrikler incelendiğinde, Durum-2'nin Durum-1'e kıyasla tutarlı biçimde daha iyi performans gösterdiği, filtreleme adımlarının segmentasyon çıktıları üzerindeki olumlu etkisini ortaya koymaktadır. Örneğin, DBK değeri Durum-1'de $91,39 \pm 3,64$ iken Durum-2'de $92,01 \pm 3,53$ 'e yükselmiş; Jİ ise $84,34 \pm 5,95$ 'ten $85,39 \pm 4,32$ 'ye çıkmıştır. GHF, Durum-1'de $13,27 \pm 9,42$ iken Durum-2'de $11,29 \pm 8,58$ 'e düşerek hacim tahmininde daha yüksek doğruluk sağlamıştır. Sınır tabanlı metriklerde de belirgin iyileşmeler gözlenmiştir: HM $52,55 \pm 13,30$ 'dan $41,39 \pm 17,42$ 'ye, HM95 $16,64 \pm 14,95$ 'ten $13,02 \pm 14,18$ 'e, OSYM ise $2,66 \pm 2,19$ 'dan $2,20 \pm 1,92$ 'ye gerilemiştir. Hem örtüşme tabanlı hem de mesafeye dayalı metriklerde elde edilen bu tutarlı iyileşmeler, Durum-2'de uygulanan filtreleme adımlarının segmentasyon sonuçlarını daha temiz, hacimsel olarak daha doğru ve sınır uyumu açısından daha güvenilir hâle getirdiğini doğrulamaktadır. Çizelge 4.19, bu nicel bulguları seçilmiş test verilerinin 3B görselleştirmeleri ile tamamlamaktadır. Bu kapsamda segmentasyon performansı en yüksek, en düşük ve ortalama metrik değerlerine sahip olmak üzere üç veri seçilmiştir. Her bir veri için Durum-1 ve Durum-2 tahmin hacmi, karşılık gelen referans hacim ile sunulmuştur.

Çizelge 4.19. Test setinde en iyi, en kötü ve orta düzeyde skorlar elde eden verilere ait referans hacim ile karşılık gelen böbrek segmentasyon sonuçlarının 3B görselleştirmesi

Durum	En iyi Veri:46		Orta Veri:1		En Kötü Veri:24	
	Referans	Tahmin	Referans	Tahmin	Referans	Tahmin
1		 DBK=%96,33		 DBK=%91,30		 DBK=%80,93
2 (Filtreli)		 DBK=%97,03		 DBK=%92,07		 DBK=%82,94

Bu düzenleme, farklı performans seviyelerinde son işlem adımlarının segmentasyon kalitesine etkisini görsel olarak karşılaştırmayı mümkün kılmaktadır. Her veri için ham ve filtrelenmiş sonuçların yan yana sunulması, gürültü baskılama ve bölge

iyileştirme adımlarının, segmentasyon doğruluğu ve sınır belirginliğine sağladığı katkıyı açıkça ortaya koymaktadır.

4.4.2. Yama tabanlı 3B ağlarla ince segmentasyon sonuçları

Bu bölümde, U-Net, AttUNet, ResUNet, MFFAU-Net ve TransUNet mimarilerinin, KiTS19 ve FLARE22 veri kümeleri üzerindeki ince segmentasyon performansları değerlendirilmektedir. Modeller, KiTS19 veri setindeki 167 eğitim ve 42 test verisi kullanılarak eğitilmiş; ardından FLARE22 veri setinden alınan 50 test örneği üzerinde genelleme yetenekleri test edilmiştir. Şekil 3.21’de şematik olarak gösterilen iş akışına uygun olarak her 128x128x16 tahmin hacimleri üretilmiş ve her bir veri için yeniden 128x128x96 halinde birleştirilmiştir (Şekil 3.21-Adım 9). Test veri setlerinden elde edilen nicel performans metrikleri Çizelge 4.20’de sunulmuştur. Bu sonuçlar, aşağı ölçeklenmiş giriş uzayında elde edilen segmentasyon kalitesini yansıtmakta ve modellerin tutarlı mekânsal koşullar altında böbrek yapılarını doğru biçimde ayırt etme yeteneğini ortaya koymaktadır. Modeller hem sağ hem de sol böbrek için DBK, Jİ ve GHF metrikleri kullanılarak değerlendirilmiştir.

KiTS19 veri seti üzerinde tüm modeller genel olarak yüksek doğrulukta performans göstermiştir. 3B U-Net, 3B ResUNet ve 3B TransUNet modelleri, DBK bakımından sırasıyla $95,77 \pm 3,09$, $95,34 \pm 3,50$ ve $95,74 \pm 3,46$ ortalama değerlerle birbirine oldukça yakın sonuçlar üretmiştir. Bu üç modelde de Jİ değerleri %91 civarında seyretmiş, bu da hacimsel benzerliğin yüksek düzeyde korunduğunu göstermektedir. Ayrıca, GHF değerlerinin ± 5 aralığında kalması, modellerin hacimsel tahminlerde dengeli bir yaklaşım sergilediğini göstermektedir. Özellikle 3B TransUNet hem yüksek DBK hem de düşük varyans (sol böbrek: DBK $95,16 \pm 2,78$, GHF $-1,76 \pm 3,69$) ile tutarlılık ve kararlılık bakımından öne çıkmıştır. Diğer yandan, 3B AttUNet modeli DBK değerlerinde %93’ün altına düşmüş ($92,26 \pm 9,18$), standart sapmasının yüksekliği ($\pm 9,18$) modelin bazı örneklerde kararsız sonuçlar ürettiğini göstermiştir. 3B MFFAU-Net varyantları (D32 ve D64), DBK açısından %94–95 seviyelerinde kalarak rekabetçi sonuçlar elde etse de GHF değerlerindeki ± 9 ’a varan değişimler, bu modellerde hacimsel dengelemenin tam olarak sağlanamadığına işaret etmektedir.

FLARE22 veri seti üzerinde tüm modellerde gözlenen genel performans düşüşü, modelin anatomik çeşitliliğe ve kontrast farklarına duyarlılığını ortaya koymaktadır. Bu veri setinde ortalama DBK değerleri tüm modeller için %83–88 aralığına gerilemiştir.

Özellikle 3B ResUNet, sağ böbrek için $88,74 \pm 4,18$, sol böbrek için $85,95 \pm 7,46$ değerleriyle, düşük standart sapma ve kararlı performans sergileyerek öne çıkan model olmuştur. 3B TransUNet, ortalama doğruluğu korumakla birlikte (sağ: $86,88 \pm 13,00$, sol: $83,29 \pm 14,31$), standart sapma değerlerinin yüksekliği modelin örnekler arası tutarlılığının azaldığını göstermektedir.

Dikkat çekici biçimde, 3B MFFAU-NetD64 sol böbrek segmentasyonlarında GHF = $-5,78 \pm 8,19$ gibi negatif değerler üretmiştir. Bu durum, modelin gerçek hacimlere kıyasla ortalama $5-6$ oranında fazla hacim tahmin ettiğini göstermekte; yani modelin hafif bir aşırı segmentasyon eğilimi sergilediğini ortaya koymaktadır. Fakat, bazı örneklerde negatif değerlerin düşük standart sapmayla ($\pm 8,19$) sınırlandığı göz önüne alındığında, bu eğilimin sistematik değil, örneğe bağlı bir durum olduğu anlaşılmaktadır.

Genel olarak değerlendirildiğinde, KiTS19 veri setinde tüm modellerin yüksek doğruluk ve hacimsel uyum sergilediği, buna karşın FLARE22 veri setinde anatomik çeşitlilik ve kontrast farklılıkları nedeniyle segmentasyon başarısının ortalama $8-10$ oranında azaldığı söylenebilir. Bu durum, eğitim verisinin anatomik kapsamının model genelleme kabiliyeti üzerinde belirleyici bir faktör olduğunu göstermektedir.

Çizelge 4.20. Yama tabanlı ağlarla elde edilen 128×128×96 çözünürlükte böbrek ince segmentasyon sonuçları (KiTS19 eğitim)

Veri Seti	Model	Sağ			Sol		
		%DBK	% Jİ	%GHF	%DBK	%Jİ	%GHF
KiTS19 Test	3B U-Net	95,77±3,09	92,04±5,37	2,10±7,19	93,59±9,5	89,04±12,29	8,51±30,14
	3B ResUNet	95,34±3,50	91,29±5,98	2,11±4,43	94,72±3,86	90,21±6,47	-0,02±5,85
	3B AttUNet	92,26±9,18	86,71±12,78	12,04±31,55	93,29±6,14	87,94±9,03	1,99±9,28
	3B MFFAU-NetD32	94,42±6,46	90,00±9,42	5,59±9,42	94,62±4,78	90,14±7,58	-1,03±5,67
	3B MFFAU-NetD64	94,98±3,14	90,60±5,31	0,02±6,73	94,53±3,44	89,82±5,83	-3,90±4,50
	3B TransUNet	95,74±3,46	92,01±5,73	2,20±6,84	95,16±2,78	90,89±4,84	-1,76±3,69
FLARE22 Test	3B U-Net	87,27±7,91	78,16±10,28	8,06±18,32	83,15±12,39	72,75±15,14	26,13±65,19
	3B ResUNet	88,74±4,18	80,01±6,58	14,66±6,59	85,95±7,46	76,04±10,44	3,43±16,62
	3B AttUNet	83,90±15,22	74,43±16,77	34,27±173,42	83,84±8,15	72,96±11,27	8,56±19,74
	3B MFFAU-NetD32	83,87±7,61	72,87±9,89	-0,43±24,22	87,00±6,87	77,60±9,88	-4,72±10,84
	3B MFFAU-NetD64	83,84±10,26	73,27±12,46	-4,40±18,75	86,88±5,65	77,22±8,31	-5,78±8,19
	3B TransUNet	86,88±13,00	78,49±14,90	6,25±52,30	83,29±14,31	73,39±16,65	13,48±45,81

Çizelge 4.21, Şekil 3.21'deki 11. adım sonrasında, tahmin edilen böbrek maskelerinin özgün boyutlarına yeniden ölçeklenmiş tam çözünürlüklü BT hacimleri içindeki anatomik konumlarına yerleştirildikten sonra elde edilen nihai segmentasyon performanslarını özetlemektedir.

KiTS19 veri seti üzerinde, modellerin büyük çoğunluğu yeniden yerleştirme sonrasında yüksek segmentasyon başarımını korumuştur. Özellikle 3B TransUNet, genel performans açısından öne çıkarak en yüksek DBK ($94,47 \pm 4,08$) ve Jİ ($89,79 \pm 6,86$) değerlerine ulaşmıştır. Bu yüksek örtüşme oranları, modelin tahmin görüntülerinin referans etiketlerle büyük ölçüde çakıştığını göstermektedir. Ayrıca GHF ($3,70 \pm 8,38$) değeri, modelin hacimsel tahminlerde dengeli ve düşük sapmalı bir davranış sergilediğini; mesafeye dayalı metrik değerleri (HM95: $5,13 \pm 6,14$ mm, OSYM: $0,91 \pm 0,84$ mm) ise sınır tahminlerinin uzamsal doğruluğunun milimetre ölçeğinde olduğunu göstermektedir.

3B ResUNet benzer biçimde yüksek DBK ($94,33 \pm 4,18$) ve Jİ ($89,55 \pm 7,07$) skorlarıyla dikkat çekmiş, GHF ($3,12 \pm 6,27$) açısından en kararlı modellerden biri olmuştur. Bununla birlikte, HM değerindeki ($33,86 \pm 7,90$ mm) hafif artış, bazı örneklerde sınırlı düzeyde kenar taşmalarının görüldüğünü göstermektedir. Bu farklara rağmen, düşük OSYM ($1,06 \pm 0,90$ mm) değeri, hataların genel olarak lokal ve düşük genlikli olduğunu işaret etmektedir. Bununla birlikte, 3B AttUNet ve MFFA tabanlı modeller özellikle GHF ve OSYM metriklerinde daha yüksek varyans göstermiştir. Örneğin AttUNet'in GHF ($15,93 \pm 26,55$) değeri, modelin bazı örneklerde hacimsel olarak aşırı veya eksik segmentasyon eğilimi sergileyebildiğini göstermektedir. MFFA-UNetD32 ve MFFA-UNetD64 varyantları, DBK açısından rekabetçi olsalar da ($92-93$ aralığında), HM95 ($\approx 6-7$ mm) ve OSYM ($\approx 1,3$ mm) değerlerinde artış gözlenmiş; bu durum, bu modellerin karmaşık anatomik sınırları tanımlamada daha duyarlı fakat değişken bir performans sergilediğini ortaya koymuştur.

Genel olarak, KiTS19 veri setinde ortalama DBK ≈ 93 , Jİ ≈ 88 ve GHF $\approx \pm 5$ aralığında seyretmiş; mesafeye dayalı metrikler açısından ise HM95 ortalama $\approx 5-7$ mm ve OSYM ≈ 1 mm civarında kalmıştır.

Çizelge 4.21. Yama tabanlı ağırlarla elde edilen tam çözünürlükte böbrek ince segmentasyon sonuçları (512x512)

Veri Seti	Model	%DBK	%Jİ	%GHF	HM [mm]	HM95 [mm]	OSYM [mm]
KiTS19 Test	3B U-Net	92,20±7,15	86,26±11,13	12,70±17,37	22,36±9,93	5,35±4,37	1,05±0,92
	3B ResUNet	94,33±4,18	89,55±7,07	3,12±6,27	33,86±7,90	5,28±4,34	1,06±0,90
	3B AttUNet	90,16±8,52	83,03±12,24	15,93±26,55	29,24±11,17	8,03±6,10	1,53±1,04
	3B MFFA-UNetD32	92,37±8,28	86,70±11,47	10,72±29,19	32,84±9,72	6,57±4,86	1,28±1,06
	3B MFFA-UNetD64	93,43±4,55	87,99±7,51	4,03±9,75	32,18±9,81	6,83±5,60	1,28±1,00
	3B TransUNet	94,47±4,08	89,79±6,86	3,70±8,38	25,19±9,98	5,13±6,14	0,91±0,84
FLARE22 Test	3B U-Net	86,71±9,41	77,61±12,97	12,28±28,19	33,14±5,70	8,83±4,63	1,83±1,00
	3B ResUNet	89,02±5,10	80,56±7,64	-5,40±7,89	36,51±7,39	11,33±3,57	2,14±0,71
	3B AttUNet	83,61±10,02	72,93±12,73	16,39±35,02	34,12±7,35	8,84±2,44	1,98±0,72
	3B MFFA-UNetD32	88,22±5,83	79,36±8,33	0,56±15,32	34,67±6,54	11,07±3,44	2,12±0,64
	3B MFFA-UNetD64	87,98±6,11	79,01±8,66	-1,87±12,26	35,63±5,59	10,86±3,37	2,18±0,73
	3B TransUNet	86,67±10,15	77,63±12,99	3,97±27,33	32,32±5,69	10,11±3,38	2,03±0,80








FLARE22 veri setinde ise tüm modellerde, artan anatomik çeşitlilik ve alan farkından (domain shift) kaynaklı olarak performans düşüşü gözlenmiştir. Bununla birlikte, 3B ResUNet en yüksek DBK değerini ($89,02 \pm 5,10$) elde etmiş ve negatif GHF ($-5,40 \pm 7,89$) değeriyle, manuel etiketlere kıyasla hacimsel olarak sistematik bir aşırı tahmin eğilimi sergilemiştir. Ancak, daha yüksek OSYM ($2,14 \pm 0,71$ mm) ve HM95 ($11,33 \pm 3,57$ mm) değerleri, yüzey doğruluğunda bir azalma olduğunu göstermektedir. MFFA tabanlı mimariler hacimsel açıdan istikrarlı sonuçlar üretse de yüzey mesafesi metriklerinde daha geniş bir varyans sergileyerek, farklı veri setleri arasında ince yapısal detayları doğru şekilde yakalama konusunda zorluk yaşadıklarını ortaya koymuştur.

MFFA tabanlı modeller, GHF açısından $\pm 5-10$ aralığında dengeli sonuçlar elde etseler de HM95 ve OSYM değerlerinde artış gözlenmiş (örneğin MFFAU-NetD64 için $HM95 \approx 10,86 \pm 3,37$ mm, $OSYM \approx 2,32 \pm 0,73$ mm); bu da bu modellerin özellikle ince anatomik sınır detaylarını doğru biçimde yeniden üretmede zorlandığını göstermektedir. 3B TransUNet, ortalama DBK ($86,67 \pm 10,15$) ile rekabetçi bir doğruluk elde etmiş, ancak OSYM ($2,03 \pm 0,80$ mm) değeriyle yüzeysel konumlama açısından görece daha iyi bir hata profili sergilemiştir.

$128 \times 128 \times 96$ çözünürlükte elde edilen ince segmentasyon sonuçları ile Adım 11 sonrasında tam çözünürlüklü birleşmiş hacim üzerinde yapılan değerlendirmeler, sağ ve sol böbreklere ait performans değerlerinin ortalaması esas alınarak karşılaştırılmıştır. Bu karşılaştırma sonucunda KiTS19 veri setinde ortalama DBK'nın tam çözünürlüklü yeniden yerleştirme adımı sonrasında yaklaşık $\%1-2$ düzeyinde azaldığı gözlenmiştir. Bu bulgu, yeniden ölçekleme ve orijinal hacme geri yerleştirme işlemlerinin örtüşme tabanlı metrikler üzerinde sınırlı bir etkiye sahip olduğunu göstermektedir.

Alan kaymasının etkisini daha sistematik biçimde değerlendirmek amacıyla, FLARE22 veri setinden yalnızca ilk 10 verinin KiTS19 veri setindeki 167 veriye eklenmesiyle toplam 177 veriden oluşan genişletilmiş bir eğitim seti oluşturulmuştur. Bu model 3B ResUNetII olarak adlandırılmıştır. Çizelge 4.21'de sunulan nicel sonuçları desteklemek amacıyla, Çizelge 4.22'de, her bir veri setinde ResUNetII modelinin ince segmentasyon performansına (DBK değeri) göre seçilen en iyi, orta ve en kötü örneklerin görsel karşılaştırmalarını göstermektedir. En iyi verilerde (örneğin, KiTS19-201 ve FLARE22-42) tüm modeller yüksek DBK değerleri (>94) elde etmiş ve sınır çizimlerinde yüksek doğruluk sergilemiştir.

Çizelge 4.22.Böbrek ince segmentasyonunda KiTS19 ve FLARE22 veri setlerinden seçilen en iyi, orta ve en kötü örneklerin görsel sonuçları

Veri	Referans	U-Net	ResUNet	AttUNet	MFFA-UNetD32	MFFA-UNetD64	TransUNet
KiTS19-201 En İyi		 DBK = %98,37	 DBK = %97,97	 DBK = %97,87	 DBK = %98,13	 DBK = %97,80	 DBK = %98,22
KiTS19-199 Orta		 DBK = %94,45	 DBK = %91,16	 DBK = %88,86	 DBK = %86,13	 DBK = %92,43	 DBK = %93,64
KiTS19-189 En Kötü		 DBK = %73,86	 DBK = %85,44	 DBK = %53,39	 DBK = %48,97	 DBK = %78,33	 DBK = %77,87
FLARE22-42 En İyi		 DBK = %95,74	 DBK = %96,01	 DBK = %94,06	 DBK = %95,48	 DBK = %95,41	 DBK = %95,09
FLARE22-14 Orta		 DBK = %82,80	 DBK = %87,80	 DBK = %82,38	 DBK = %88,22	 DBK = %89,04	 DBK = %87,28
FLARE22-41 En Kötü		 DBK = %51,73	 DBK = %67,20	 DBK = %40,86	 DBK = %59,60	 DBK = %61,00	 DBK = %38,95

Model eğitime sınırlı sayıda FLARE22 örneğinin eklenmesi, modelin hedef alana ilişkin temel bir alan farkındalığı edinmesini amaçlamıştır. Ancak eklenen örneklerin sayıca az olması, FLARE22 veri setinin cihaz, protokol ve anatomik çeşitliliğini tam olarak yansıtmaya yetmemiştir. Bu nedenle, eğitime dahil edilmeyen test örneklerinde alan uyumsuzluğuna bağlı hatalar özellikle yüzey tabanlı metriklerde belirgin şekilde ortaya çıkmıştır. Bununla birlikte, kullanılan örneklerin sınırlı olmasına rağmen modelin FLARE22 alanına yönelik duyarlılığında ölçülebilir bir artış sağlanmıştır; bu durum ilgili bölümde sunulan nicel bulgularla desteklenmiştir.













Çizelge 4.23'te sunulan sonuçlara göre, yalnızca KiTS19 verisiyle eğitilen 3B ResUNet modeli KiTS19 test setinde ortalama %94,33 DBK ve 1,06 mm OSYM değeriyle yüksek doğruluk sergilemiştir. Ancak aynı model FLARE22 test setinde %89,02 DBK ve 2,14 mm OSYM değerlerine düşmüş, özellikle HM95 (11,33 mm) gibi sınır duyarlılığı yüksek metriklerde performans kaybı gözlenmiştir. Bu durum, modelin farklı tarayıcı ve görüntüleme protokollerinden kaynaklanan yoğunluk değişimlerine duyarlı olduğunu göstermektedir.

Çizelge 4.23. Böbrek ince segmentasyonunda FLARE22 verilerinin eğitime dahil edilmemesinin (3B ResUNet) ve edilmesinin (3B ResUNetII) performansa etkisi

Test Verisi	Model	%DBK	%Jİ	%GHF	HM [mm]	HM95 [mm]	OSYM [mm]
KiTS19	3B ResUNet	94,33±4,18	89,55±7,07	3,12±6,27	33,86±7,90	5,28±4,34	1,06±0,90
FLARE22		89,02±5,10	80,56±7,64	-5,40±7,89	36,51±7,39	11,33±3,57	2,14±0,71
KiTS19	3B ResUNetII	93,00±5,62	87,39±9,04	8,87±11,03	27,76±12,31	6,55±1,23	1,15±1,23
FLARE22		90,71±5,99	83,50±9,03	0,47±12,91	33,16±5,75	8,07±3,45	1,58±0,69

Buna karşılık, sınırlı sayıda FLARE22 örneğini içeren 3B ResUNetII modeli, FLARE22 test setinde genel performans artışı sağlamıştır. DBK değeri %89,02'den %90,71'e, Jİ %80,56'dan %83,50'ye yükselirken, GHF değeri %-5,40'tan %0,47'ye gerilemiştir. Ayrıca sınır tabanlı metriklerde de belirgin iyileşme gözlenmiş, HM95 değeri 11,33 mm'den 8,07 mm'ye, OSYM ise 2,14 mm'den 1,58 mm'ye düşmüştür. Bu bulgular, hedef alana ait az sayıda örnekle gerçekleştirilen kısmi alan uyarlamasının bile modelin genel dayanıklılığını artırdığını ve anatomik çeşitliliğe sahip veri kümelerine genelleme kapasitesini geliştirdiğini göstermektedir. Bu bulguları niteliksel olarak desteklemek amacıyla, Çizelge 4.24'te her iki test kümesinden seçilen en iyi, orta ve en kötü ince segmentasyon görsel sonuçları sunulmuştur.

Çizelge 4.24. KiTS19 ve FLARE22 veri setlerinden seçilen en iyi, orta ve en zayıf performans gösteren örneklerde ResUNet ve ResUNetII modellerinin böbrek ince segmentasyon performansı

Veri	Referans	ResUNet	ResUNetII
Kits19-201 En İyi		 DBK = %97,97	 DBK = %98,28
Kits19-199 Orta		 DBK = %91,16	 DBK = %93,12
Kits19-189 En Kötü		 DBK = %85,44	 DBK = %73,60
FLARE22-42 En İyi		 DBK = %96,01	 DBK = %97,34
FLARE22-14 Orta		 DBK = %87,80	 DBK = %90,50
FLARE22-41 En Kötü		 DBK = %67,20	 DBK = %65,77

En iyi örneklerde (örneğin KiTS19-201 ve FLARE22-42), model tarafından üretilen segmentasyon maskeleri anatomik sınırlarla yüksek düzeyde uyum göstermekte ve referans segmentasyonla neredeyse tam örtüşmektedir. Buna karşılık, en zayıf performansın gözlemlendiği verilerde (örneğin KiTS19-189 ve FLARE22-41), modelin alan kayması, yoğunluk farklılıkları ve anatomik varyasyonu yönetme becerisinin yetersiz kaldığı; özellikle ince yapıların sınır bütünlüğünde bozulmaların ve eksik yakalamaların belirginleştiği gözlenmektedir.

Özellikle FLARE22 veri setinde elde edilen iyileşmeler dikkat çekicidir; ancak KiTS19 üzerinde gözlemlenen küçük düşüş, önemli bir denge durumuna işaret etmektedir: hedef alan verisinin modele dahil edilmesi genelleme kabiliyetini artırabilir, ancak kaynak alan üzerindeki tutarlılığı bir miktar zayıflatabilir. Bu durum hem hedef hem de kaynak alan performansını koruyacak şekilde çapraz alan dayanıklılığını artıran iyi kalibre edilmiş alan uyarlama stratejilerinin gerekliliğini vurgulamaktadır.

Sonuç olarak, deneyler sınırlı hedef alan verisinin dahil edilmesinin bile modelin alan kayması etkilerine karşı kısmi direnç kazandığını ortaya koymuştur.

4.4.3. Nokta bulutu tabanlı ağlar ile ince segmentasyon sonuçları

Böbrek ince segmentasyonu aşamasında, PointNet ve DGKSA olmak üzere nokta tabanlı derin öğrenme mimarilerinin performansı, Şekil 3.17'nin 10. Adımında elde edilen segmentasyon çıktıları kullanılarak sistematik olarak değerlendirilmiştir. Her iki model de KiTS23 veri setinde yüksek segmentasyon doğruluğu elde etmiş ve eğitim alanındaki güçlü öğrenme kapasitesini ortaya koymuştur. Ancak, FLARE22 veri setinde belirgin bir performans düşüşü gözlenmiştir, bu da modellerin alan kaymasına duyarlılığını ve veri kümeleri arasında güçlü genelleme sağlamanın zorluklarını vurgulamıştır. Bu durum, 3B U-Net ile gözlemlenen davranış ile de benzerlik göstermektedir.

Nokta bulutu dönüşümü sırasında hesaplama karmaşıklığını ve bellek gereksinimlerini yönetebilmek amacıyla alt-örnekleme (sub-sampling) stratejisi uygulanmıştır. PointNet için her iki noktadan biri alınarak (yani her 2 noktadan 1'i seçilerek) nokta sayısı yarıya düşürülmüştür. Bu yaklaşım, geometrik bütünlüğün korunması ile nokta yoğunluğunun azaltılması arasında dengeli bir yapı sağlamıştır. DGKSA modelinde ise daha güçlü bir alt-örnekleme stratejisi benimsenmiş ve her üç noktadan yalnızca biri seçilmiştir. Bu yöntem, dinamik grafik oluşturma sürecindeki bellek yükünü önemli ölçüde azaltırken, ince yapısal detayların kaybolma olasılığını da artırmıştır. Bu tasarım tercihleri, hesaplama verimliliği ile segmentasyon doğruluğu arasındaki dengeyi açık biçimde ortaya koymaktadır.

ÖO Qi ve ark. (2017a) tarafından PointNet için rapor edilen yapılandırmaya uygun olarak 0,001 olarak belirlenmiştir. YB değeri PointNet için 6, daha yüksek bellek gereksinimleri nedeniyle DGKSA için ise 2 olarak seçilmiştir. Çizelge 4.25, alt-örneklenmiş nokta bulutları kullanılarak KiTS23 ve FLARE22 veri setlerinde her iki böbrek için elde edilen ince segmentasyon sonuçlarını göstermektedir.

Çizelge 4.25. Eksik nokta örnekleme durumunda, PointNet ve DGKSA modellerine ait her iki böbrek ağı için 128×128×96 pencere boyutlarında elde edilen ince segmentasyon sonuçları

Model	Veri Seti	Sol Böbrek			Sağ Böbrek		
		[%] DBK	[%] Jİ	[%] GHF	[%] DBK	[%] Jİ	[%] GHF
PointNet	Eğitim (Kits23)	85,96±15,75	77,59±16,39	8,64±11,16	86,80±10,44	77,96±13,89	7,84±9,84
	Test (FLARE22)	67,78±14,42	52,99±16,03	32,19±18,25	45,58±16,49	30,96±13,67	36,27±23,06
DGKSA	Eğitim (Kits23)	86,07±8,13	76,34±11,21	8,58±8,97	86,39±7,59	76,75±10,58	8,77±9,34
	Test (FLARE22)	83,35±5,70	71,86±8,22	11,63±9,23	81,56±8,16	69,60±10,72	15,99±14,79

Eksik nokta örnekleme altında elde edilen deneysel bulgular, her iki modelin de veri dağılımındaki değişimlere ve uygulanan örnekleme stratejisine belirgin ölçüde duyarlı olduğunu ortaya koymaktadır. PointNet, KiTS23 eğitim verisinde oldukça yüksek performans sergileyerek sol böbrek için %85,96 ve sağ böbrek için %86,80 DBK değerlerine ulaşmıştır. Bu sonuçlar, modelin eğitim verisi üzerinde güçlü bir temsil öğrenebildiğini göstermektedir. Ancak, FLARE22 test verisinde belirgin bir performans düşüşü gözlenmiştir; sol böbrek için DBK ortalama %67,78'e, sağ böbrek için ise %45,58'e gerilemiştir. Bu dikkate değer bozulma, PointNet'in alan kaymasına karşı yüksek duyarlılığını ve farklı veri dağılımlarında genelleme kabiliyetinin sınırlı olduğunu göstermektedir. Ayrıca, GHF değerlerindeki artış, modelin sınır bölgelerinde yapısal bütünlüğü korumakta zorlandığını işaret etmektedir.

DGKSA modeli ise veri kümeleri arasında daha kararlı ve dengeli bir performans ortaya koymuştur. KiTS23 eğitim setinde sol böbrek için %86,07 ve sağ böbrek için %86,39 ortalama DBK değerleri elde edilmiştir. Bu değerler PointNet'ten bir miktar düşük olsa da modelin genel segmentasyon başarımının yüksek olduğu görülmektedir. FLARE22 test setine geçildiğinde DGKSA'nın performansındaki düşüş oldukça sınırlı kalmış; sol böbrek için %83,35, sağ böbrek için ise %81,56 ortalama DBK değerleri elde edilmiştir. Bu bulgular, DGKSA'nın dinamik grafik yapısının, nokta bulutu içindeki yerel geometrik ilişkileri etkili biçimde yakalayarak genelleme yeteneğini güçlendirdiğini göstermektedir.

Genel olarak, bu sonuçlar eksik nokta örnekleme altında nokta bulutu tabanlı DGKSA modelinin, PointNet'e kıyasla daha yüksek alan genellemesi (cross-domain generalization) ve yapısal dayanıklılık sergilediğini ortaya koymaktadır.

Alt-örneklemenin segmentasyon performansına etkisini değerlendirmek amacıyla ek bir deney gerçekleştirilmiştir. Bu deneyde, test veri setindeki nokta bulutu dönüşümü herhangi bir alt-örnekleme yapılmadan, tüm pikseller kullanılarak uygulanmıştır.

Şekil 3.17'de, nokta bulutu oluşturma süreci adım 8 kapsamında her iki mimari için kullanılan örnekleme stratejileri özetlenmiştir:

PointNet için, x ve y eksenlerinde her 2 pikselde bir örnekleme yapılmıştır. Bu işlem sonucunda hacim $64 \times 64 \times 96$ boyutlarına indirgenmiş ve toplam 393216 nokta elde edilmiştir. Eğitim aşamasında bu nokta bulutu, her biri 65536 nokta içeren 6 alt bloğa ayrılmış ve her blok modelin girişine ayrı ayrı sunulmuştur (Şekil 3.17-Adım 8).

DGKSA mimarisi için, x ve y eksenlerinde her 3 pikselde bir örnekleme uygulanmıştır. Bu işlem sonucunda toplam 177504 nokta oluşturulmuş; veri, bellek

kullanımını optimize etmek amacıyla her biri 29584 nokta içeren 6 alt bloğa ayrılmış ve bu parçalar etiket bilgileriyle birlikte DGKSA ağına giriş olarak verilmiştir (Şekil 3.17-Adım 8).

Tam çözünürlüklü test sürecinde, her iki mimari için de önceden atlanan noktalar yeniden değerlendirmeye dahil edilmiştir.

- PointNet için: Eğitim sırasında kullanılan örnekleme stratejisi korunmuş, ancak bu kez ilk atlanan noktalardan başlanarak yeni bir tam örnekleme yapılmıştır. Böylece, eğitimde kullanılan 6 blokluk yapıya ek olarak sırasıyla ikinci, üçüncü ve dördüncü 6×65536 'lık bloklar oluşturulmuştur. Sonuçta, tam çözünürlüklü test hacmi 24×65536 (toplam 1572864 nokta) olacak biçimde yapılandırılmış ve bu veri, orijinal çözünürlükteki $128 \times 128 \times 96$ hacme karşılık gelecek şekilde yeniden düzenlenmiştir.
- DGKSA için: Tam çözünürlüklü test aşamasında, x ve y eksenlerinde yapılan 3 piksel aralıklı örnekleme adımı kaldırılarak tüm noktalar yeniden işleme alınmıştır. Böylece, orijinal hacimdeki tüm noktalar kullanılarak toplam 1597536 nokta elde edilmiştir. Bu nokta kümesi, modelin bellek sınırlarını aşmadan işlenebilmesi için 54 alt bloğa bölünmüştür. Her bir blok yaklaşık 29584 nokta içermekte olup, her nokta için $[x, y, z, gri\ seviye]$ olmak üzere dört boyutlu bilgi taşımaktadır. Sonuç olarak, DGKSA modeli için tam çözünürlüklü nokta bulutu verisi $54 \times 29584 \times 4$ boyutunda bir tensör yapısına dönüştürülmüştür. Bu bloklar sırasıyla ağa giriş olarak verilmiş, model sonuçları yeniden birleştirilerek tam çözünürlüklü segmentasyon hacmi elde edilmiştir.

Bu düzenleme, DGKSA mimarisinin eksiksiz geometrik bilgiyle çalışmasını sağlayarak alt örnekleme sonucu oluşabilecek bilgi kayıplarını ortadan kaldırmıştır. Böylece, alt örnekleme stratejilerinin hesaplama verimliliği, bellek gereksinimi ve segmentasyon doğruluğu üzerindeki etkileri doğrudan ve karşılaştırmalı biçimde değerlendirilebilmiştir. Alt örneklenmiş ve tam çözünürlüklü nokta bulutu girdileri kullanılarak gerçekleştirilen testler sonucunda, PointNet ve DGKSA modellerinin karşılaştırmalı performans sonuçları Çizelge 4.26'da özetlenmiştir.

Her iki model, hesaplama maliyetini azaltmak amacıyla alt örneklenmiş nokta bulutlarıyla eğitilmesine rağmen, tam çözünürlüklü girişlerle yapılan testlerde anlamlı performans farklılıkları ortaya çıkmıştır. Bu durum, model mimarilerinin çözünürlük duyarlılığına ve uzamsal detayları temsil etme kapasitelerine işaret etmektedir.

DGKSA modeli, tam çözünürlüklü nokta bulutlarıyla değerlendirildiğinde, eksik nokta örnekleme kullanılan test senaryosuna (Çizelge 4.25) kıyasla segmentasyon performansında sınırlı ancak tutarlı bir iyileşme göstermiştir. Çizelge 4.26’da sunulan filtresiz sonuçlara göre, sol böbrek için ortalama DBK değeri %83,35’ten %83,66’ya, sağ böbrek için ise %81,56’dan %81,74’e yükselmiştir. Buna paralel olarak, ortalama GHF değeri sol böbrekte %11,63’ten %11,44’e düşerken, sağ böbrekte %15,99’dan %15,78’e gerilemiştir. Bu bulgular, DGKSA modelinin seyrek nokta bulutlarıyla eğitilmiş olmasına rağmen, tam çözünürlüklü veri girişlerinde bulunan ince uzamsal ayrıntıları daha etkin biçimde değerlendirebildiğini göstermektedir.

PointNet modeli ise iki farklı test koşulu arasında oldukça sınırlı ve tutarsız bir performans değişimi sergilemiştir. Tam nokta bulutları kullanıldığında, sol böbrek için ortalama DBK değeri %67,76’dan %67,83’e çok sınırlı bir artış gösterirken, sağ böbrek için %45,18’den %45,14’e hafif bir düşüş gözlenmiştir. Benzer biçimde, ortalama GHF değerleri sol böbrekte %32,67’den %34,52’ye yükselmiş, sağ böbrekte ise %38,71 seviyesinde sabit kalmıştır. Bu bulgular, PointNet mimarisinin artan nokta yoğunluğuna karşı düşük duyarlılık gösterdiğini ve ek geometrik bilgidен yararlanma kapasitesinin sınırlı kaldığını ortaya koymaktadır. Genel olarak değerlendirildiğinde, DGKSA modelinin daha zengin uzamsal temsillere uyum sağlama yeteneğinin belirgin biçimde daha güçlü olduğu ve bunun özellikle veri kümeleri arası segmentasyon senaryolarında daha yüksek genelleme performansına katkı sunduğu görülmektedir.

Değerlendirmeyi ayrıntılandırmak amacıyla, tam çözünürlüklü nokta bulutları üzerinde elde edilen tahminler BBA tabanlı bir son işlem aşamasından geçirilmiştir. Bu aşamada, 100’den az noktaya sahip küçük ve bağlantısız bileşenler elenerek anatomik tutarlılık artırılmıştır. Filtreleme sonrası sonuçlar Çizelge 4.26’da PointNet (Filtreli) ve DGKSA (Filtreli) olarak sunulmuş; özellikle DGKSA modelinde DBK ve Jİ metriklerinde artış, GHF değerlerinde ise belirgin düşüşler gözlenmiştir.

Çizelge 4.26. Tam nokta bulutu girişi kullanılarak, 128×128×96 pencere boyutlarında değerlendirilen PointNet ve DGKSA modellerinin her iki böbrek ağı için ince segmentasyon performansı

Model	Sol Böbrek			Sağ Böbrek		
	[%] DBK	[%] Jİ	[%] GHF	[%] DBK	[%] Jİ	[%] GHF
PointNet	67,76±14,56	53,00±16,13	32,67±17,97	45,18±16,58	30,63±13,64	38,71±23,83
PointNet (Filtreli)	67,83±15,22	53,20±16,83	34,52±18,80	45,14±17,05	30,64±14,02	38,71±24,03
DGKSA	83,66±5,62	72,30±8,11	11,44±9,44	81,74±8,27	69,87±10,79	15,78±15,50
DGKSA (Filtreli)	84,70±5,79	73,87±8,45	10,20±8,69	83,01±8,58	71,77±11,41	13,97±13,76



















DGKSA modeli için uygulanan bu filtreleme işlemi, örtüşme tabanlı metriklerde orta düzeyde bir iyileşme sağlamıştır. Sol böbrek için ortalama DBK değeri %84,70'e, sağ böbrek için ise %83,01'e yükselmiş; buna karşılık ortalama Jİ değerleri sırasıyla %73,87 ve %71,77 olarak kaydedilmiştir. Ortalama GHF değerleri sol böbrek için %10,20'ye, sağ böbrek için ise %13,97'ye düşmüştür. Bu sonuçlar, segmentasyonların anatomik açıdan daha tutarlı ve düzgün sınırlar sergilediğini göstermektedir. Ayrıca, hacim tabanlı ölçütlerde gözlenen sapmalara rağmen, tahmin edilen böbrek hacimlerinin genel eğiliminin gerçek hacimlerle uyumlu olduğu ve filtrasyon işleminin hacim tutarlılığını büyük ölçüde koruduğu görülmektedir.

PointNet modeline uygulanan filtreleme işlemi ise ortalama DBK değerlerinde yalnızca sınırlı değişikliklere neden olmuştur (sol böbrek %67,83, sağ böbrek %45,14). Buna karşın ortalama GHF değerlerinde artış gözlenmiştir (sırasıyla %34,52 ve %38,71). Bu bulgular, başlangıçtaki segmentasyon kalitesi düşük olduğunda filtreleme sürecinin mevcut hataları derinleştirebileceğini ve bazı geçerli yapıların yanlışlıkla kaldırılması sonucunda performansın daha da gerileyebileceğini göstermektedir.



















Genel olarak, elde edilen sonuçlar BBA tabanlı son işlem adımının etkinliğinin temel segmentasyon kalitesine doğrudan bağlı olduğunu ortaya koymaktadır. Temel segmentasyonun güvenilir ve iyi yapılandırılmış olduğu durumlarda (örneğin DGKSA modelinde olduğu gibi) bu yaklaşım genel çıktı kalitesini artırabilirken, segmentasyon sonuçlarının parçalı veya gürültülü olduğu durumlarda (örneğin PointNet modelinde) performansın daha da düşmesine neden olabilmektedir.

Çizelge 4.27 ve Çizelge 4.28, PointNet ve DGKSA modelleriyle tam nokta bulutu girişi kullanılarak elde edilen sol ve sağ böbrek için en iyi, orta ve en kötü segmentasyon örneklerini göstermektedir. Her bir durumda, modelin ham tahmini, buna karşılık gelen referans nokta bulutu ve filtrelenmiş tahmin olmak üzere üç ayrı görselleştirme sunulmuştur.

Çizelge 4.27. FLARE22 veri seti üzerinde PointNet modeliyle elde edilen en iyi, orta ve en düşük böbrek ince segmentasyon sonuçlarının görsel karşılaştırması

Böbrek Pozisyonu	Performans Veri	Tahmin	Referans	Filtreli Tahmin
Sol	En İyi Veri:33	 DBK= %91,14		 DBK= %91,38
	Orta Veri:43	 DBK= %72,43		 DBK= %72,52
	En Kötü Veri:18	 DBK= %32,08		 DBK= %29,15
Sağ	En İyi Veri:47	 DBK= %77,37		 DBK= %77,78
	Orta Veri:46	 DBK= %46,41		 DBK= %46,74
	En Kötü Veri:48	 DBK= %0,25		 DBK= %0

Çizelge 4.28. FLARE22 veri seti üzerinde DGKSA modeliyle elde edilen en iyi, orta ve en düşük böbrek ince segmentasyon sonuçlarının görsel karşılaştırması

Böbrek Pozisyonu	Performans Veri	Tahmin	Referans	Filtreli Tahmin
Sol	En İyi Veri:28	 DBK= %91,78		 DBK= %93,19
	Orta Veri:25	 DBK= %84,60		 DBK= %85,63
	En Kötü Veri:16	 DBK= %68,77		 DBK= %68,93
Sağ	En İyi Veri:33	 DBK= %92,47		 DBK= %93,49
	Orta Veri:21	 DBK= %83,73		 DBK= %85,13
	En Kötü Veri:24	 DBK= %48,24		 DBK= %48,69

4.5. Pankreas Segmentasyonu Sonuçları

4.5.1. Kaba segmentasyon sonuçları

Bu bölümde, pankreasın kaba konumunun belirlenmesine yönelik ilk aşama segmentasyon modelinden elde edilen nicel sonuçlar sunulmaktadır. Model, 256×256 boyutundaki yama tabanlı girişlerle çalışmakta olup bu yapı, tüm hacimde doğrudan segmentasyon yapıldığında ortaya çıkacak yüksek hesaplama maliyetini azaltmayı amaçlamaktadır.

256×256 pencere boyutuna ilişkin sonuçlar Çizelge 4.29’da sunulmaktadır. Çıkarılan pencerelerin 512×512 boyutundaki pencereye yeniden yerleştirilmesiyle elde edilen sonuçlar Çizelge 4.30’da sunulmaktadır.

Çizelge 4.29. 256×256 pencere için ResUNet ile pankreas kaba segmentasyon sonuçları

Eğitim Verisi	Test Verisi	[%] DBK	[%] Jİ
MSD Task07 Pankreas	MSD Task07 Pankreas	66,27±23,61	53,44±22,31
MSD Task07 Pankreas	FLARE22	85,36±9,89	75,56±12,94
MSD Task07 Pankreas ve FLARE22	MSD Task07 Pankreas	62,73±25,24	49,95±23,40
MSD Task07 Pankreas ve FLARE22	FLARE22	82,91±11,31	72,15±14,00

Çizelge 4.30. 256×256 pencerelerin orijinal 512×512 düzlemlerine geri yerleştirilmesiyle oluşturulan tam çözünürlükteki pankreas kaba segmentasyon sonuçları

Eğitim Verisi	Test Verisi	[%] DBK	[%] Jİ
MSD Task07 Pankreas	MSD Task07 Pankreas	67,25±24,06	54,78±23,11
MSD Task07 Pankreas	FLARE22	86,41±9,05	77,04±12,22
MSD Task07 Pankreas ve FLARE22	MSD Task07 Pankreas	63,76±25,80	51,35±24,38
MSD Task07 Pankreas ve FLARE22	FLARE22	83,92±10,52	73,51±13,42

Yalnızca MSD veri setiyle eğitilen model, 256×256 pencerelerde MSD test setinde DBK %66,27 iken, 512×512 tam pencerede %67,25’e yükselmiştir. Benzer şekilde Jİ ise %53,44’ten %54,78’e artmıştır. Bu, kırılmış sonuçların tam pencereye yerleştirilmesinin küçük de olsa bir iyileştirme sağladığını göstermektedir. FLARE22 test setinde de aynı modelin performansı DBK açısından %85,36’dan %86,41’e, Jİ açısından %75,56’dan %77,04’e yükselmiştir.

MSD verilerine ek olarak 10 adet FLARE22 verisinin dahil edildiği durumda ise MSD test setindeki performans, 256×256 pencerede DBK %62,73 iken 512×512

pencerede %63,76'ya yükselmiştir. Jİ değeri de %49,95'ten %51,35'e çıkmıştır. FLARE22 test setinde de benzer şekilde DBK %82,91'den %83,92'ye, Jİ %72,15'ten %73,51'e iyileşmiştir.

Bu bulgular, sınırlı sayıda farklı veri eklemenin her zaman genelleme performansını artırmadığını, hatta bazı durumlarda eğitim verilerindeki dağılım farklılıkları nedeniyle test performansında dalgalanmalara yol açabileceğini göstermektedir.

4.5.2. Pankreas İA kırpma işleminden elde edilen nicel sonuçlar

Kaba segmentasyon sonunda elde edilen tahmin filtrelerine 3B BBA uygulanmış Pankreas İA elde edilmiştir. MSD Task07 Pankreas veri setinde elde edilen İA'ların istatistiksel özellikleri Çizelge 4.31'de sunulmaktadır. Bu veriler dikkate alınarak ince segmentasyon için pencere boyutu seçilmiştir. Çizelgede pankreas İA pencere boyutlarının maksimum, minimum, ortalama ve standart sapma değerleri sunulmaktadır.

Çizelge 4.31. Pankreas kaba segmentasyon sonucu kesilen pencerelerin istatistiksel özellikleri

Veri	Min -Maks Yükseklik	Min -Maks Genişlik	Min -Maks Derinlik	Ort – Std Yükseklik	Ort – Std Genişlik	Ort – Std Derinlik
Eğitim	44-156	74-257	16-80	91,07±21,05	157,74±31,34	34,25±9,13
Test	44-172	100-229	14-152	90,44±23,67	166,90±28,70	38,59±21,61


4.5.3. Pankreas ince segmentasyonu sonuçları

4.5.3.1. Voksel tabanlı mimarilerin sonuçları

Bu bölümde, pankreas ince segmentasyonu için kullanılan voksel tabanlı derin öğrenme mimarilerinin (U-Net, ResUNet ve TransUNet) elde ettiği sonuçlar sunulmaktadır. Çalışma kapsamında, hem pencere düzeyinde hesaplanan değerlendirme skorları hem de bu pencerelerin yeniden ölçeklenmiş orijinal hacim konumlarına yerleştirilmesiyle elde edilen tam hacim skorları ayrı olarak analiz edilmiştir.

Şekil 4.7'de, 176×96×d İA boyutlarında yürütülen voksel tabanlı modellerin ince segmentasyon deneylerinin performans sonuçları sunulmaktadır. U-Net modeli, MSD Task07_Pancreas test setinde %63,08 ± 20,02 DBK ve %48,98 ± 19,77 Jİ, FLARE22 test setinde ise %79,41 ± 11,99 DBK ve %67,10 ± 13,50 Jİ değerlerine ulaşmıştır. Bu

sonuçların üzerinde bir performans sergileyen ResUNet modeli, MSD test setinde $67,35 \pm 20,14$ DBK ve $53,84 \pm 20,44$ Jİ, FLARE22 test setinde ise $83,43 \pm 12,94$ DBK ve $73,29 \pm 15,58$ Jİ elde ederek her iki veri kümesinde de en başarılı model olmuştur. TransUNet modeli ise MSD test setinde $60,90 \pm 22,04$ DBK ve $47,07 \pm 21,06$ Jİ, FLARE22 test setinde ise $74,25 \pm 17,12$ DBK ve $61,63 \pm 19,17$ Jİ değerleriyle U-Net ve ResUNet modellerinin gerisinde kalmıştır. Bu bulgular, özellikle $176 \times 96 \times d$ İA yapılandırmasında ResUNet mimarisinin pankreas segmentasyonunda daha istikrarlı ve yüksek doğruluk sunduğunu göstermektedir.




Şekil 4.5. MSD Task07 Pankreas ve FLARE22 veri setleri üzerinde U-Net, ResUNet ve TransUNet modellerinin ince segmentasyon performanslarının $176 \times 96 \times d$ pencere için karşılaştırmalı gösterimi

Şekil 4.8’de, $512 \times 512 \times d$ İA boyutlarında gerçekleştirilen ince segmentasyon deneylerinin sonuçları karşılaştırmalı olarak sunulmaktadır. U-Net modeli, MSD Task07_Pancreas test setinde $64,19 \pm 20,45$ DBK ve $50,34 \pm 20,59$ Jİ, FLARE22 test setinde ise $80,24 \pm 10,97$ DBK ve $68,22 \pm 13,35$ Jİ değerlerine ulaşmıştır.

ResUNet modeli, MSD test setinde $68,22 \pm 20,57$ DBK ve $55,05 \pm 21,20$ Jİ, FLARE22 test setinde ise $84,23 \pm 12,51$ DBK ve $74,37 \pm 15,15$ Jİ elde ederek, $176 \times 96 \times d$ İA sonuçlarına göre hafif bir performans artışı sergilemiştir. Bu artış hem ortalama değerlere hem de hata çubuklarında temsil edilen daha düşük varyansa yansımaktadır. TransUNet modeli de MSD test setinde $61,95 \pm 22,64$ DBK ve $48,44$

$\pm 22,02$ Jİ, FLARE22 test setinde ise $\%75,09 \pm 16,81$ DBK ve $\%62,63 \pm 18,95$ Jİ değerlerine ulaşmış; ancak her iki veri setinde de ResUNet ve U-Net modellerine kıyasla daha düşük bir performans göstermiştir.






Şekil 4.6. MSD Task07 Pankreas ve FLARE22 veri setleri üzerinde U-Net, ResUNet ve TransUNet modellerinin ince segmentasyon performanslarının 512x512 pencere için karşılaştırmalı gösterimi

İnce segmentasyon sonuçları genel olarak, kaba segmentasyona kıyasla sınırlı fakat tutarlı iyileşmeler sağlamıştır. Örneğin, ResUNet modelinin MSD test seti DBK değeri kaba segmentasyonda $\%67,25$ iken ince segmentasyonda $\%68,22$ 'ye yükselmiştir. Jİ skorlarında da benzer şekilde küçük artışlar izlenmiştir. Bu bulgular, yüksek çözünürlüklü İA'lar üzerinde gerçekleştirilen ince segmentasyonun daha ayrıntılı anatomik bilgi yakalayarak belirli avantajlar sunduğunu, ancak performans kazanımının genel olarak sınırlı kaldığını göstermektedir. Bununla birlikte, FLARE22 test setinde kaba segmentasyon sonuçlarının bazı durumlarda daha başarılı olduğu da dikkat çekmektedir.


İnce segmentasyon aşamasında elde edilen 3B U-Net, ResUNet ve TransUNet modellerine ait örnek sonuçlar, MSD ve FLARE22 veri setlerinden seçilen en iyi ve en kötü veri örnekleri üzerinde görselleştirilmiştir. Çizelge 4.32'de MSD veri setinde en yüksek başarıya sahip veri (Veri389, DBK = $\%91,42$) ve en düşük performanslı veri (Veri409, DBK = $\%9,11$); FLARE22 veri setinde ise en iyi sonuç (Veri40, DBK = $\%96,13$) ve en düşük başarıya sahip örnek (Veri14, DBK = $\%28,75$) gösterilmektedir.

Çizelge 4.32. 3B ResUNet kullanılarak yapılan pankreas ince segmentasyon sonuçlarının görsel karşılaştırması

Veri Seti	Referans Görüntü	Tahmin Görüntüsü	Referans Görüntü	Tahmin Görüntüsü
	En İyi		En Kötü	
Task07				
	Pancreas_389	DBK = %91,42	Pancreas_409	DBK = %9,11
FLARE22				
	FLARE22_Tr_0040	DBK = %96,13	FLARE22_Tr_0014	DBK = %28,75

4.5.3.2. Nokta bulutu tabanlı mimarilerin ince segmentasyon sonuçları

Pankreas segmentasyonu probleminde genel olarak, her iki nokta tabanlı ağ da umut verici segmentasyon performansları sergilemiştir; ancak DGKSA, her iki veri kümesinde de PointNet'ten tutarlı biçimde daha yüksek başarı elde etmiştir. Bu sonuç, DGKSA'nın dinamik grafik öznitelik öğrenimi sayesinde yerel geometrik yapıları daha etkin biçimde yakalayabildiğini göstermektedir. Şekil 4.7, nokta bulutu tabanlı ağlar kullanılarak gerçekleştirilen pankreas ince segmentasyonunun değerlendirme sonuçlarını göstermektedir. Grafik, PointNet ve DGKSA modellerinin MSD Task07 Pankreas ve FLARE22 test veri setleri üzerindeki performansını %DBK ve %Jİ metrikleri açısından karşılaştırmalı olarak sunmaktadır. Bu karşılaştırma, nokta tabanlı mimarilerin farklı veri setlerinde sergilediği doğruluk seviyeleri ve varyasyonları hakkında kapsamlı bir değerlendirme sağlamaktadır.



Şekil 4.7. MSD Task07 Pankreas ve FLARE22 veri setleri üzerinde PointNet ve DGKSA modellerinin pankreas ince segmentasyon performanslarının karşılaştırmalı gösterimi









MSD Task07 Pankreas veri kümesinde DGKSA modeli, DBK açısından $69,00 \pm 12,50$, Jİ açısından ise $53,94 \pm 13,42$ elde ederek PointNet modeline göre sırasıyla 5,22 puan ve 6,30 puan daha yüksek bir performans göstermiştir (PointNet: DBK $63,78 \pm 10,32$; Jİ $47,64 \pm 10,95$).

FLARE22 veri kümesinde her iki modelin performansları birbirine yakın olmakla birlikte DGKSA modeli yine hafif bir üstünlük sağlamıştır; DBK $76,05 \pm 5,16$ ve Jİ $61,63 \pm 6,65$ değerlerine ulaşmıştır. PointNet ise aynı veri kümesinde DBK $74,67 \pm 6,11$, Jİ $59,94 \pm 7,47$ üretmiştir.









FLARE22 sonuçlarında DGKSA'nın daha düşük standart sapma değerleri (DBK: $\pm 5,16$; Jİ: $\pm 6,65$), modelin öğrenme sürecinde daha kararlı bir performans sergilediğini ve örnekler arası anatomik varyasyonlara karşı daha az duyarlılık gösterdiğini doğrulamaktadır.

Ayrıca, her iki modelin sağlamlığını daha ayrıntılı biçimde değerlendirmek amacıyla yapılan veri düzeyindeki karşılaştırma, Çizelge 4.33 ve Çizelge 4.34'te sunulmuştur. Bu çizelgelerde, PointNet modeli için elde edilen en iyi ve en kötü örneklerin görsel sonuçları yer almaktadır.

Çizelge 4.33. PointNet kullanılarak gerçekleştirilen pankreas ince segmentasyonun veri düzeyinde değerlendirilmesi

Test Veri Seti	En İyi Sonuç		En Kötü Sonuç	
	Referans	Tahmin	Referans	Tahmin
MSD	 Pankreas_367	 DBK = %83,29	 Pankreas_414	 DBK = %35,85
FLARE22	 FLARE22_Tr_0040	 DBK = %84,45	 FLARE22_Tr_0014	 DBK = %55,75

Çizelge 4.34. DGKSA kullanılarak gerçekleştirilen pankreas ince segmentasyonun veri düzeyinde değerlendirilmesi

Test Veri Seti	En İyi Sonuç		En Kötü Sonuç	
	Referans	Tahmin	Referans	Tahmin
MSD	 Pankreas_375	 DBK = %85,01	 Pankreas_414	 DBK = %31,21
FLARE22	 FLARE22_Tr_0040	 DBK = %89,01	 FLARE22_Tr_0026	 DBK = %74,51

5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, böbrek ve pankreas segmentasyonu problemleri, voksel tabanlı ve nokta bulutu tabanlı derin öğrenme yöntemleri kullanılarak kapsamlı biçimde incelenmiştir. Çalışma kapsamında, farklı morfolojik özelliklere sahip bu iki organ üzerinden, veri temsiline bağlı performans farklılıkları ayrıntılı olarak analiz edilmiş; böylece derin öğrenme modellerinin organ-spesifik zorluklara karşı adaptasyon ve genelleme yetenekleri değerlendirilmiştir.

Böbrek segmentasyonu için düşük hesaplama maliyetli yama tabanlı voksel yöntemler üzerinde durulmuş ve iki aşamalı bir kaba–ince segmentasyon çerçevesi tasarlanmıştır. İlk aşamada düşük çözünürlüklü hacimler kullanılarak kaba lokalizasyon gerçekleştirilmiş, ikinci aşamada ise yüksek çözünürlüklü İA'lar üzerinde ayrıntılı segmentasyon uygulanmıştır. Bu kapsamda U-Net, AttUNet, ResUNet, MFFAU-Net ve TransUNet mimarileri değerlendirilmiş; KiTS19, KiTS23 ve FLARE22 veri setleri üzerinde gerçekleştirilen kapsamlı deneyler sonucunda, voksel tabanlı yöntemlerin organ segmentasyonunda yüksek doğruluk sunduğu ancak hesaplama maliyeti, veri çeşitliliği ve genelleme kabiliyeti açısından hâlâ sınırlılıklar taşıdığı gözlemlenmiştir.

Voksel tabanlı yöntemlerin bu sınırlılıklarına yanıt olarak, tezde nokta bulutu tabanlı derin öğrenme yaklaşımları da araştırılmıştır. Nokta bulutu temsili, üç boyutlu verileri doğrudan $[x, y, z]$ koordinatları ve gri seviye (yoğunluk) bilgisi üzerinden ifade ederek veri boyutunu önemli ölçüde azaltmakta; aynı zamanda geometrik ilişkilerin korunmasını ve hafif, bellek dostu bir işlem altyapısının oluşturulmasını sağlamaktadır. Bu kapsamda, PointNet ve DGKSA mimarileri pankreas verisi üzerinde uygulanmış; farklı örnekleme stratejileri ve nokta sayıları altında modellerin dayanıklılığı ve öğrenme kararlılığı değerlendirilmiştir. Elde edilen sonuçlar, nokta bulutu tabanlı mimarilerin özellikle pankreas segmentasyonu gibi morfolojik olarak karmaşık, düzensiz sınırlara ve düşük kontrastlı doku geçişlerine sahip organlarda üstün performans sergileyebildiğini ortaya koymuştur.

Genel değerlendirme sonucunda, nokta bulutu tabanlı yaklaşımlar, hesaplama verimliliği ve uzamsal-geometrik bilgi kaybını en aza indirme açısından önemli avantajlar sunmaktadır. Buna karşılık, nokta bulutu oluşturma aşamasında anatomik bütünlüğün korunması, yoğunluk bilgisinin doğru şekilde aktarılması ve nokta örnekleme stratejisinin model performansı üzerindeki etkisi, gelecekte detaylı biçimde araştırılması gereken başlıca konular arasında yer almaktadır.


Bu tez çalışmasıyla birlikte, tıbbi görüntü segmentasyonunda nokta bulutu temsiline dayalı yöntemlerin uygulanabilirliği sistematik biçimde ortaya konulmuş; böbrek ve pankreas segmentasyonları üzerinden yapılan kapsamlı analizler aracılığıyla, veri temsili–performans ilişkisine dair özgün bulgular literatüre kazandırılmıştır.

5.1. Sonuçlar

5.1.1. Abdomen segmentasyonu sonuçları

Abdomen segmentasyonunda, 2B derin öğrenme tabanlı mimarilerin performanslarını değerlendirmek ve önerilen 3B U-Net modelinin etkinliğini ortaya koymak amacıyla kapsamlı bir karşılaştırmalı analiz gerçekleştirilmiştir. Bu kapsamda, 2B U-Net, Diakogiannis ve ark. (2020) tarafından önerilen ResUNet, Zhou ve ark. (2018) tarafından geliştirilen U-Net++, Oktay ve ark. (2018) tarafından sunulan AttU-Net ve önerilen 3B U-Net mimarileri 10-katlı çapraz doğrulama yöntemi ve sabit öğrenme oranı ($\text{ÖÖ} = 0,001$) kullanılarak değerlendirilmiştir. Şekil 5.1, abdomen segmentasyonunda kullanılan farklı modellerin test veri seti üzerindeki performanslarının çok yönlü metriklerle karşılaştırmalı değerlendirmesini sunmaktadır. Bulgular, 3B U-Net mimarisinin tüm 2B tabanlı modellere kıyasla belirgin biçimde üstün bir performans ortaya koyduğunu göstermektedir. Özellikle 3B U-Net, %99,71 DBK ve %99,42 Jİ ile en yüksek doğruluk değerlerine ulaşarak, hacimsel 3B temsilin sunduğu zengin uzamsal bağlamın segmentasyon başarımını anlamlı ölçüde artırdığını doğrulamaktadır. Bu sonuçlar, derinliğe dayalı üç boyutlu mimarilerin karmaşık anatomik yapıları daha etkin yakalayabildiğini açık biçimde ortaya koymaktadır.

Elde edilen sonuçlar, 3B U-Net mimarisinin tüm diğer yaklaşımlara kıyasla üstün bir performans sergilediğini ortaya koymaktadır. Bu model, %99,71 DBK ve %99,42 Jİ ile en yüksek doğruluğa ulaşırken, aynı zamanda %0,22 GHF değeriyle en düşük hacimsel sapmayı elde etmiştir. Özellikle ince anatomik detayların korunmasını değerlendiren FDK metriğinde %92,45 ile en yüksek değere ulaşarak diğer tüm mimarilerin belirgin biçimde önüne geçmiştir.



Şekil 5.1. Abdomen segmentasyonunda kullanılan farklı modellerin test veri seti üzerindeki performanslarının karşılaştırılması

Karşılaştırmalı olarak, ResUNet, artık bağlantılar ile gradyan kaybı problemini azaltmayı ve özellik yayılımını artırmayı hedefleyen bir U-Net türevi olup, %99,52 DBK ve %74,40 FDK değeri ile başarılı bir performans göstermiştir. U-Net++, iç içe ve yoğun atlama bağlantıları (dense skip connections) sayesinde çok ölçekli özellik füzyonunu güçlendirmiş ve %99,54 DBK ile %75,27 FDK değeri elde ederek ResUNet'e kıyasla ince yapıların segmentasyonunda sınırlı da olsa bir iyileşme sağlamıştır. AttU-Net, dikkat mekanizmaları (attention mechanisms) sayesinde özellik seçimini optimize etmiş ve %99,56 DBK ile %75,54 FDK değeri elde ederek ResUNet ve U-Net++'nın her ikisini de yapısal ayrıntıların korunmasında geride bırakmıştır.

Buna ek olarak, literatürde Dorgham ve ark. (2022) tarafından kullanılan 2B U-Net modeli yeniden uygulanmış ve ortalama %99,56 DBK değeri elde edilmiştir. Ancak, %67,79 FDK sonucu, 2B mimarilerin ince ayrıntıların korunmasında belirgin kısıtlılık taşıdığını göstermektedir.

Elde edilen tüm bulgular, 3B U-Net'in segmentasyon doğruluğu ve ince yapısal bilgiyi koruma konusunda açık bir üstünlük sunduğunu göstermektedir. Bununla birlikte, ResUNet, U-Net++ ve AttU-Net gibi gelişmiş 2B mimariler, görece düşük hesaplama maliyetleriyle belirli senaryolarda tercih edilebilir alternatifler sunmaktadır.

Ayrıca, önerilen 3B U-Net modelinin çıktılarına uygulanan İA kesme işlemi sonucunda, yaklaşık %33 oranında veri azaltımı sağlanmıştır. Bu durum, sonraki aşamada gerçekleştirilecek çalışmalar için işlem yükünü önemli ölçüde azaltmış, modelin hem bellek verimliliğini hem de hesaplama hızını artırmıştır.

Sonuç olarak, 3B U-Net mimarisinin, abdomen bölgesinin hacimsel yapısını daha bütüncül biçimde öğrenerek yüksek doğruluk, düşük hata oranı ve yüksek genelleme kabiliyeti sunduğu; ayrıca veri hacmini optimize eden bir ön-segmentasyon aşaması olarak sonraki organ-spesifik modeller için güçlü bir temel oluşturduğu belirlenmiştir.

5.1.2. Böbrek segmentasyonu sonuçları

Bu tez kapsamında, böbrek segmentasyonu amacıyla geliştirilen iki farklı yaklaşımın performansı kapsamlı biçimde değerlendirilmiştir. Her iki yaklaşımda da kaba segmentasyon aşaması, U-Net tabanlı mimariler kullanılarak böbrek İA'larının belirlenmesi üzerine kurulmuştur. Bu adım, işlem hacmini veri yapısına göre daraltarak işlenecek veri boyutunu önemli ölçüde azaltmış ve sonraki ince segmentasyon süreçlerinde hesaplama verimliliğini artırmıştır. Birinci yaklaşımda, elde edilen İA'lar üzerinde üç farklı mimari —voksel tabanlı 3B U-Net ile nokta bulutu tabanlı PointNet ve DGKSA— karşılaştırılmıştır.

Birinci yaklaşımda, elde edilen İA'lar üzerinde üç farklı mimari —voksel tabanlı 3B U-Net ile nokta bulutu tabanlı PointNet ve DGKSA— karşılaştırılmıştır. 3B U-Net modeli, KiTS23 veri setinde %98,04 (sol böbrek) ve %96,66 (sağ böbrek) DBK ile yüksek doğrulukta sonuçlar üretmiştir. FLARE22 test setinde ise her iki böbrek için ortalama DBK değerleri yaklaşık %93 seviyesinde gerçekleşmiş; uygulanan son-işlem adımları sonrasında bu oran yaklaşık %94'e yükselmiştir. Mesafeye dayalı metriklerde (HM, HM95, OSYM) gözlenen iyileşmeler, son işlem adımlarının sınır tutarlılığını artırdığını göstermektedir.

İkinci yaklaşımda, çok aşamalı yama tabanlı bir çerçeve kullanılarak 3B U-Net, AttUNet, ResUNet, MFFAU-Net ve TransUNet mimarileri değerlendirilmiştir. KiTS19 veri seti üzerinde yapılan deneyler, TransUNet ve ResUNet mimarilerinin %94'ün üzerinde DBK değerleriyle en yüksek performansı sunduğunu göstermiştir. FLARE22 veri setinde ise genelleme performansındaki düşüşe rağmen, ResUNet ve MFFAU-Net modellerinin diğer mimarilere göre daha dengeli sonuçlar verdiği gözlenmiştir. Bu bulgular, dikkat mekanizmaları, dönüştürücü tabanlı öz-dikkat modülleri ve çok ölçekli özellik çıkarımı yaklaşımlarının karmaşık anatomik yapılarda anlamlı iyileşmeler sağladığını göstermektedir.

Genel olarak, her iki yaklaşımın sonuçları birlikte değerlendirildiğinde:

- Kaba segmentasyonun işlem hacmini %60'ın üzerinde azaltarak sonraki aşamalarda hem eğitim süresini kısalttığı hem de model kararlılığını artırdığı,
- Voksel tabanlı modellerin yüksek doğruluk ve hacimsel bütünlük sağlarken daha yüksek hesaplama maliyetine sahip olduğu,
- Nokta bulutu tabanlı modellerin özellikle DGKSA mimarisiyle birlikte, güçlü geometrik genelleme kabiliyeti sunduğu,
- Filtreleme ve son işlem adımlarının, sınır hatalarını azaltarak HM ve OSYM metriklerinde anlamlı iyileşmeler sağladığı tespit edilmiştir.

Literatürde böbrek segmentasyonuna yönelik gerçekleştirilen çalışmalar Çizelge 5.1'de özetlenmiştir.

Çizelge 5.1. Böbrek segmentasyonunda önerilen yöntemlerin mevcut derin öğrenme tabanlı yaklaşımlarla karşılaştırmalı performansı

Çalışma	Veri Seti	% DBK
da Cruz ve ark. (2020)	Kits19	96
Kim ve ark. (2020)	Kits19	71
Fatemeh ve ark. (2020)	Özel (315 BT)	95,79
Fatemeh ve ark. (2020)	Kits19	96,25
Xie ve ark. (2020)	Kits19	96,7
Türk ve ark. (2020)	Kits19	97,7
Zhao ve ark. (2020)	Kits19	96,9
Lin ve ark. (2021)	Özel (441 BT)	97,3
Zeng ve ark. (2021)	70 BT	91
Pandey ve Gupta (2022)	Kits19	97,62
Kittipongdaja ve ark. (2022)	Kits19	95,95
Kittipongdaja ve ark. (2022)	Özel (4 BT)	87,60
Sun ve ark. (2023)	Kits19	97,5
Bu Çalışma 3B U-Net (1.Yaklaşım)	FLARE22	92,00
Bu Çalışma DGKSA (1.Yaklaşım)	FLARE22	83,86
Bu Çalışma 3B TransUNet (2.Yaklaşım)	Kits19	94,47
Bu Çalışma 3B ResUNetII (2.Yaklaşım)	FLARE22	90,71

Bu çalışmalarda modellerin büyük çoğunluğu, aynı veri setinin bir kısmıyla eğitilip kalan kısmıyla test edilerek değerlendirilmiştir. Dolayısıyla raporlanan yüksek DBK değerleri genellikle aynı dağılım üzerinde elde edilmiştir ve gerçek klinik uygulamalarda karşılaşılan alan kayması etkisi sınırlı düzeyde incelenmiştir. Buna karşılık, bu tez kapsamında geliştirilen yöntemler farklı kaynaklardan elde edilen veri

setleri üzerinde test edilerek daha zorlu bir genelleme senaryosu değerlendirilmiştir. Önerilen çerçeve, FLARE22 veri setinde 3B U-Net ile %92,00 (Kits23 veri setiyle eğitim durumu), 3B ResUNetII modeliyle %90,71 (Kits19 ve FLARE22 veri setinden sınırlı veri eklenmesiyle eğitim) DBK değerine ulaşmış; böylece kurumlar arası dağılım farklılıklarına rağmen kararlı performans sergilemiştir. Bu sonuçlar, alan kayması içeren bir senaryoda %87,60 DBK raporlayan Kittipongdaja ve ark. (2022) gibi çalışmalardan daha yüksek doğruluk sunarak, yöntemin güçlü genelleme kabiliyetini ortaya koymaktadır.

5.1.3. Pankreas segmentasyonu sonuçları

Pankreas segmentasyonu, organın küçük hacmi, düzensiz morfolojisi ve bireyler arasındaki belirgin anatomik farklılıklar nedeniyle literatürde en zorlu organ segmentasyon problemlerinden biri olarak değerlendirilmektedir.

Yöntemin ilk aşamasında, 256×256 boyutundaki BT hacimleri üzerinde yama tabanlı 3B ResUNet mimarisi kullanılarak kaba segmentasyon gerçekleştirilmiş ve pankreasın yaklaşık konumu belirlenmiştir. Bu aşama, tüm hacim üzerinde doğrudan işlem yapmanın neden olacağı yüksek hesaplama maliyetini azaltmış ve modeli organın İA'sına odaklayarak öğrenme sürecinin verimliliğini artırmıştır.

İkinci aşamada, ilk aşamada belirlenen İA kullanılarak ince segmentasyon işlemi gerçekleştirilmiştir. Bu kapsamda, derin özellik çıkarımı ve dikkat (attention) mekanizmalarının avantajlarını birleştiren 3B U-Net, 3B ResUNet ve 3B TransUNet mimarileri karşılaştırılmış; ayrıca hacimsel verilerin yüzey temsillerini doğrudan değerlendirebilmek amacıyla nokta bulutu tabanlı PointNet ve DGKSA ağları da ince segmentasyon sürecine dahil edilmiştir. Nokta bulutu tabanlı bu yaklaşımlar, 3B yüzey geometrisini doğrudan işleyebilme yetenekleri sayesinde özellikle sınır belirsizliği yüksek bölgelerde daha hassas segmentasyon sağlamıştır.

Nicel sonuçlar, önerilen çok aşamalı yapının hem MSD Task07 Pankreas hem de FLARE22 veri setlerinde güçlü bir performans sergilediğini göstermektedir. MSD Task07 Pankreas veri setinde U-Net modeli $\%63,08 \pm 20,02$ DBK ve $\%48,98 \pm 19,77$ Jİ ile temel bir referans performansı ortaya koymuştur. ResUNet modeli $\%67,35 \pm 20,14$ DBK ve $\%53,84 \pm 20,44$ Jİ ile U-Net'in üzerinde bir doğruluk elde ederken, TransUNet modeli $\%60,90 \pm 22,04$ DBK ve $\%47,07 \pm 21,06$ Jİ sonuçlarıyla her iki modele kıyasla daha düşük bir performans sergilemiştir. Nokta bulutu tabanlı ağlardan PointNet, $\%63,78$

$\pm 10,32$ DBK ve $\%47,64 \pm 10,95$ Jİ ile TransUNet'ten daha yüksek doğruluk sunmuştur. DGKSA modeli ise $\%69,00 \pm 12,50$ DBK ve $\%53,94 \pm 13,42$ Jİ değerleri ile hem vokal tabanlı hem nokta bulutu tabanlı tüm modellerin üzerinde bir başarı göstererek en yüksek doğruluğa ulaşmıştır. Bu bulgular, DGKSA'nın dinamik komşuluk grafiğine dayalı yapısının yerel geometrik özellikleri daha etkin biçimde öğrenebildiğini göstermektedir.

FLARE22 veri setinde ise tüm modellerin performanslarının genel olarak daha yüksek seviyede olduğu görülmüştür. U-Net modeli $\%79,41 \pm 11,99$ DBK ve $\%67,10 \pm 13,50$ Jİ değerlerine ulaşarak güçlü bir temel doğruluk sağlamıştır. ResUNet modeli $\%83,43 \pm 12,94$ DBK ve $\%73,29 \pm 15,58$ Jİ ile en yüksek performansı sergilemiştir. TransUNet modeli $\%74,25 \pm 17,12$ DBK ve $\%61,63 \pm 19,17$ Jİ ile U-Net'in altında bir doğruluk göstermiştir. Nokta bulutu tabanlı modellerden PointNet $\%74,67 \pm 6,11$ DBK ve $\%59,94 \pm 7,47$ Jİ ile TransUNet'ten daha istikrarlı bir yapı sergilerken, DGKSA modeli $\%76,05 \pm 5,16$ DBK ve $\%61,63 \pm 6,65$ Jİ performansı ile nokta bulutu tabanlı modeller arasında en yüksek doğruluğa ulaşmış ve vokal tabanlı mimarilere yakın bir başarı elde etmiştir. Ayrıca PointNet ve DGKSA'nın düşük standart sapma değerleri, nokta bulutu temsillerinin FLARE22 veri setindeki anatomik varyasyonlara karşı daha kararlı bir öğrenme davranışı sergilediğini göstermektedir.

Bu bulgular, nokta bulutu tabanlı temsillerin karmaşık organ sınırlarını ve uzamsal varyasyonları daha etkili biçimde yakalayabildiğini ortaya koymaktadır. Özellikle DGKSA modeli, yerel geometrik ilişkileri dinamik olarak modelleyebilmesi sayesinde, küçük ve düzensiz şekilli pankreas yapısının sınırlarını daha başarılı şekilde belirleyebilmiştir. Ayrıca Jİ metriklerinin DBK ile tutarlı eğilim göstermesi, nokta bulutu tabanlı geometrik öznitelik öğreniminin klasik vokal tabanlı ağlara kıyasla daha kararlı ve hassas segmentasyonlar üretebildiğini doğrulamaktadır.

Çizelge 5.2'de literatürde MSD Task07 Pankreas veri seti üzerinde raporlanan segmentasyon sonuçları sunulmaktadır. Literatürde bildirilen DBK'lar genellikle $\%73$ ile $\%83$ aralığında değişmektedir. Xie ve ark. (2019) $\%73,6$, Chen ve ark.(2022) $\%76,6$, Cao ve ark.(2023) $\%75,53$ ve Liang ve ark. (2025) $\%82,7$ oranında DBK başarımı elde ettiklerini raporlamışlardır.

Çizelge 5.2. MSD Task07 Pankreas veri seti üzerinde literatür ve bu çalışma tarafından raporlanan pankreas segmentasyonu sonuçlarının karşılaştırılması

Çalışma	Veri Seti	[%] DBK	[%] Jİ
Xie ve ark.(2019)	MSD	73,6	59,1
Chen ve ark.(2022)	MSD	76,6	62,6
Cao ve ark.(2023)	MSD	75,53	-
Liang ve ark. (2025)	MSD	82,7	71,25
Bu çalışma -ResUNet	MSD	67,35	53,84
Bu çalışma -DGKSA	MSD	69,00	53,94
Bu çalışma -ResUNet	MSD eğitim/ FLARE22 test	84,23	74,37

Bu çalışmada yalnızca MSD verisi ile eğitilen ResUNet modeli, aynı veri setinde %67,35 DBK ve %53,84 Jİ değerleri elde etmiştir. Bu değerler literatürde bildirilen en yüksek başarımların altında kalmakla birlikte, yöntemin yama tabanlı ve donanım açısından sınırlı bir yaklaşımla uygulanmış olması dikkate değer görülmektedir.

Buna karşın, MSD verisi ile eğitilen modelin FLARE22 test setinde %84,23 DBK ve %74,37 Jİ başarımı göstermesi, önerilen yöntemin farklı veri setlerine karşı genellenebilirliğini ortaya koymaktadır. Bu sonuç, önerilen yaklaşımın özellikle alan kayması senaryolarında literatürdeki pek çok yöntemle rekabet edebilecek düzeyde olduğunu göstermektedir.

Sonuç olarak, önerilen çok aşamalı yaklaşım, hesaplama maliyetini önemli ölçüde düşürürken yüksek doğrulukta pankreas segmentasyonu sağlamış; nokta bulutu tabanlı DGKSA modeli ise özellikle morfolojik karmaşıklığın yüksek olduğu durumlarda voksel tabanlı modellere güçlü bir alternatif sunmuştur. Bu yönüyle önerilen çerçeve hem doğruluk hem de verimlilik açısından literatürdeki yöntemlerle rekabet edebilir niteliktedir.

5.1.4. Segmentasyon modellerinin hesaplama maliyetlerinin analizi

Segmentasyon aşamasında kullanılan modeller, mimari yapı ve parametre sayıları bakımından iki temel grupta incelenebilir: voksel tabanlı hacimsel KSA modelleri ve nokta bulutu tabanlı modeller. Voksel tabanlı 3B U-Net, 3B ResUNet, 3B AttUNet ve TransUNet gibi mimariler, 60–110 milyon parametre aralığında yer alan oldukça büyük yapılara sahiptir. Bu durum, modellerin yüksek temsil kapasitesi sunmasına karşın önemli bir hesaplama yükü oluşturmaktadır. Öte yandan nokta bulutu tabanlı DGKSA (~0,98 milyon) ve PointNet (~1,60 milyon) modelleri, bu hacimsel yapılara kıyasla yaklaşık 60–110 kat daha az parametre içermekte ve oldukça kompakt bir mimari sunmaktadır. Hafif

bir voksel tabanlı yaklaşım olan MFFAU-NetD32'nin 22 milyon parametreye kadar düşmesi ise kodlayıcı filtre boyutlarının hesaplama gereksinimi üzerindeki kritik etkisini açıkça göstermektedir. Segmentasyon modellerinin kodlayıcı yapıları ile toplam parametre sayılarının karşılaştırılması Çizelge 5.3'te sunulmuştur.

Çizelge 5.3. İnce segmentasyon modellerin kodlayıcı yapıları ile toplam parametre sayılarının karşılaştırılması

Model	Kodlayıcı Filtre Sayısı	Parametre Sayısı
3B U-Net	64 – 128 – 256 – 512	90319746
3B ResUNet	64 – 128 – 256 – 512	91727298
3B AttUNet	64 – 128 – 256 – 512	91018950
3B MFFAU-NetD32	32 – 64 – 128 – 256	22967262
3B MFFAU-NetD64	64 – 128 – 256 – 512	61137850
3B TransUNet	64 – 128 – 256 – 512	111311746
PointNet	-	1606290
DGKSA	-	980096

Her ne kadar nokta bulutu tabanlı DGKSA ve PointNet modelleri parametre sayısı bakımından son derece küçük olsa da bu durum, eğitim süresinde doğrusal bir hızlanma sağlamamaktadır. Bunun temel nedenlerinden biri, nokta bulutu temelli algoritmaların hesaplama karakteristiğinin voksel tabanlı evrişimlerden önemli ölçüde farklı olmasıdır. Voksel tabanlı 3B KSA modelleri düzenli tensör yapısı üzerinde yoğun paralel evrişim hesaplamaları gerçekleştirebildiği için GPU mimarisiyle yüksek oranda örtüşürken; nokta bulutu tabanlı modellerde KNN aramaları, komşuluk grafiği oluşturma, dinamik kenar özellikleri çıkarımı ve düzensiz bellek erişimi gibi işlemler ek hesaplama maliyeti oluşturmaktadır. Ayrıca nokta bulutu dönüşümünde her örneğin $[x, y, z, yoğunluk]$ şeklinde dört boyutlu bir öznitelik vektörüyle temsil edilmesi, işlem adımlarında nokta başına daha karmaşık ilişkilerin modellenmesini gerektirmekte ve bu nedenle parametre sayısındaki azalma eğitim süresine birebir karşılık gelmemektedir.

Bu bulgular, segmentasyon modellerindeki hesaplama maliyetinin yalnızca parametre büyüklüğü ile değil; algoritmik karmaşıklık, veri temsil biçimi ve GPU mimarisiyle uyumluluk gibi faktörlerle birlikte değerlendirilmesi gerektiğini göstermektedir. Bununla birlikte, nokta bulutu tabanlı modellerin parametre sayısını 60–100 kat azaltan son derece hafif yapıları, bellek kullanımını düşürmeleri, daha küçük modellerin dağıtımını kolaylaştırmaları ve düşük donanımlı ortamlarda çalışmaya daha elverişli olmaları bakımından önemli bir avantaj sunmaktadır. Bu çalışmada tüm noktalar işleme dahil edilmiş olmakla birlikte, nokta bulutu temsiline özgü olarak sadece bilgi içeren noktaların hesaplama katılabilmesi; medikal hacimlerde geniş yer kaplayan

siyah arka plan bölgelerinin hesaplama maliyetine yansımamasını sağlayabilecek potansiyel bir verimlilik avantajı sunmaktadır.

5.2. Öneriler

Bu tez çalışması, tıbbi görüntülerden nokta bulutu temelli organ ayrıştırmanın uygulanabilir olduğunu göstermiş; işlem yükünün azaltılması, yapısal bilginin doğrudan öğrenilmesi ve bellek gereksiniminin düşüklüğü gibi önemli üstünlükler sunmuştur. Bununla birlikte, yöntemin hem doğruluk hem de farklı durumlara uyum açısından geliştirilebilecek yönleri bulunmaktadır. Bu doğrultuda gelecekte yürütülebilecek çalışmalar aşağıda özetlenmiştir.

Bu tezde kullanılan örnekleme yöntemi, her verinin belirli sayıda noktaya indirgenmesi esasına dayanmaktadır. Nokta bulutunun daha anlamlı ve yapı duyarlı biçimde oluşturulması için uyarlanabilir örnekleme (sınır bölgelerinde daha sık, benzer dokulu alanlarda daha seyrek), yoğunluk düzenleme ve gürültü giderme işlemlerinin kullanılması önerilmektedir. Bu tür geliştirmeler, özellikle pankreas, safra kanalı ve damar yapıları gibi ince, düzensiz ve düşük karışıklığa sahip organların daha doğru temsil edilmesini sağlayarak yöntemin başarısını artırabilir.

Öte yandan, yalnızca nokta bulutu temelli yöntemler yüzey ve şekil bilgisini işlerken, hacim tabanlı yöntemler tüm kütle bilgisini daha iyi değerlendirebilmektedir. Bu nedenle her iki yaklaşımın güçlü yanlarını bir araya getiren birleşik yapılar gelecek çalışmalar için önem taşımaktadır. Önce hacim tabanlı kaba bir ayrıştırma yapılması ve ardından nokta bulutu ile ayrıntılı bir düzeltme uygulanması, iki tür bilginin aynı ağ içinde birleştirilmesi veya seyrek hesaplama yöntemleri ile nokta temelli dikkat düzeneklerinin birlikte kullanılması hem hacimsel hem yüzeysel bilgilerin daha eksiksiz öğrenilmesine katkı sağlayacaktır.

Son olarak, bu tezde yöntem böbrek gibi sınırları daha belirgin bir organ üzerinde değerlendirilmiştir. Yöntemin gerçek klinik koşullardaki gücünü görmek için safra yolları, damar dallanmaları ve tümör-sağlıklı doku geçişleri gibi daha düzensiz ve ayırt edilmesi güç yapılar üzerinde de sınanması gerekmektedir. Bu tür ince ve karmaşık bölgelerde nokta bulutu temsiliyle ne ölçüde başarılı sonuç alınabileceğinin araştırılması, yöntemin uygulama alanını genişletecek önemli bir çalışma başlığıdır.

KAYNAKLAR

- Albishri, A., Shah, S. J., ve Lee, Y. (2019). *CU-Net: Cascaded U-Net Model for Automated Liver and Lesion Segmentation and Summarization*. <https://doi.org/10.1109/BIBM47256.2019.8983266>
- Amiri, M., Brooks, R., ve Rivaz, H. (2019). Fine tuning U-net for ultrasound image segmentation: Which layers? *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11795 LNCS, 235-242. https://doi.org/10.1007/978-3-030-33391-1_27
- Asadpour, V., Parker, R. A., Mayock, P. R., Sampson, S. E., Chen, W., ve Wu, B. (2021). Pancreatic cancer tumor analysis in CT images using patch-based multi-resolution convolutional neural network. *Biomedical Signal Processing and Control*, 68, 102652. <https://doi.org/https://doi.org/10.1016/j.bspc.2021.102652>
- Azad, R., Heidary, M., Yilmaz, K., Hüttemann, M., Karimijafarbigloo, S., Wu, Y., ... Merhof, D. (2023). Loss functions in the era of semantic segmentation: A survey and outlook. *arXiv preprint arXiv:2312.05391*.
- Benčević, M., Qiu, Y., Galić, I., ve Pižurica, A. (2023). Segment-then-Segment: Context-Preserving Crop-Based Segmentation for Large Biomedical Images. *Sensors*, C. 23. <https://doi.org/10.3390/s23020633>
- Cao, L., Li, J., ve Chen, S. (2023). Multi-target segmentation of pancreas and pancreatic tumor based on fusion of attention mechanism. *Biomedical Signal Processing and Control*, 79, 104170. <https://doi.org/10.1016/j.bspc.2022.104170>
- Charilaou, P., ve Battat, R. (2022). Machine learning models and over-fitting considerations. *World Journal of Gastroenterology*, 28, 605-607. <https://doi.org/10.3748/wjg.v28.i5.605>
- Chen, H., Liu, Y., Shi, Z., ve Lyu, Y. (2022). Pancreas segmentation by two-view feature learning and multi-scale supervision. *Biomedical Signal Processing and Control*, 74, 103519. <https://doi.org/10.1016/j.bspc.2022.103519>
- Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., ... Zhou, Y. (2021). Transunet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*.
- Chen, L., Bentley, P., Mori, K., Misawa, K., Fujiwara, M., ve Rueckert, D. (2019). Self-supervised learning for medical image analysis using image context restoration. *Medical image analysis*, 58, 101539.
- Chen, Y., Xu, C., Ding, W., Sun, S., Yue, X., ve Fujita, H. (2022). Target-aware U-Net with fuzzy skip connections for refined pancreas segmentation. *Applied Soft Computing*, 131, 109818.

- Christ, P. F., Elshaer, M. E. A., Ettlinger, F., Tatavarty, S., Bickel, M., Bilic, P., ... D'Anastasi, M. (2016). Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields. *International conference on medical image computing and computer-assisted intervention*, 415-423. Springer.
- 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. Springer.
- da Cruz, L. B., Araújo, J. D. L., Ferreira, J. L., Diniz, J. O. B., Silva, A. C., de Almeida, J. D. S., ... Gattass, M. (2020). Kidney segmentation from computed tomography images using deep neural network. *Computers in Biology and Medicine*, 123, 103906.
- Diakogiannis, F. I., Waldner, F., Caccetta, P., ve Wu, C. (2020). ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 94-114.
- Dorgham, O., Naser, M. A., Ryalat, M. H., Hyari, A., Al-Najdawi, N., ve Mirjalili, S. (2022). U-NetCTS: U-Net deep neural network for fully automatic segmentation of 3D CT DICOM volume. *Smart Health*, 26, 100304. <https://doi.org/https://doi.org/10.1016/j.smhl.2022.100304>
- Fatemeh, Z., Nicola, S., Satheesh, K., ve Eranga, U. (2020). Ensemble U-net-based method for fully automated detection and segmentation of renal masses on computed tomography images. *Medical physics*, 47(9), 4032-4044.
- Fu, Y., Lei, Y., Wang, T., Curran, W. J., Liu, T., ve Yang, X. (2021). A review of deep learning based methods for medical image multi-organ segmentation. *Physica Medica*, 85, 107-122.
- Gibson, E., Giganti, F., Hu, Y., Bonmati, E., Bandula, S., Gurusamy, K., ... Barratt, D. (2018). Automatic Multi-Organ Segmentation on Abdominal CT With Dense V-Networks. *IEEE Transactions on Medical Imaging*, PP, 1. <https://doi.org/10.1109/TMI.2018.2806309>
- Girshick, R., Donahue, J., Darrell, T., ve Malik, J. (2013). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR.2014.81>
- Han, X., Tang, Y., Wang, Z., ve Li, X. (2024). *Mamba3D: Enhancing Local Features for 3D Point Cloud Analysis via State Space Model* (C. 1). Association for Computing Machinery. Geliş tarihi gönderen <http://arxiv.org/abs/2404.14966>
- He, K., Gkioxari, G., Dollár, P., ve Girshick, R. (2017). Mask R-CNN. *2017 IEEE International Conference on Computer Vision (ICCV)*, 2980-2988. <https://doi.org/10.1109/ICCV.2017.322>
- He, Kaiming, Gkioxari, G., Dollár, P., ve Girshick, R. (2017). *Mask R-CNN*.

- He, Kaiming, Zhang, X., Ren, S., ve Sun, J. (2015). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. Geliş tarihi gönderen <https://api.semanticscholar.org/CorpusID:206594692>
- He, L., Ren, X., Gao, Q., Zhao, X., Yao, B., ve Chao, Y. (2017). The connected-component labeling problem: A review of state-of-the-art algorithms. *Pattern Recognition*, 70, 25-43.
- Hu, P., Li, X., Tian, Y., Tang, T., Zhou, T., Bai, X., ... Li, J. (2020). Automatic pancreas segmentation in CT images with distance-based saliency-aware DenseASPP network. *IEEE journal of biomedical and health informatics*, 25(5), 1601-1611.
- Hussain, S., Mubeen, I., Ullah, N., Shah, S. S. U. D., Khan, B. A., Zahoor, M., ... Sultan, M. A. (2022). Modern Diagnostic Imaging Technique Applications and Risk Factors in the Medical Field: A Review. *BioMed Research International*, 2022, 5164970. <https://doi.org/10.1155/2022/5164970>
- Ioffe, S., ve Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International conference on machine learning*, 448-456. pmlr.
- Isensee, F., Jaeger, P. F., Kohl, S. A. A., Petersen, J., ve Maier-Hein, K. H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods*, 18(2), 203-211.
- Jha, A., Yang, H., Deng, R., Kapp, M. E., Fogo, A. B., ve Huo, Y. (2021). Instance segmentation for whole slide imaging: end-to-end or detect-then-segment. *Journal of Medical Imaging*, 8(1), 14001.
- Kanaujia, V. K., Kumar, A., ve Yadav, S. P. (2024). Advancements in Automatic Kidney Segmentation Using Deep Learning Frameworks and Volumetric Segmentation Techniques for CT Imaging: A Review. *Archives of Computational Methods in Engineering*, 31(5), 3151-3169. <https://doi.org/10.1007/s11831-024-10067-w>
- Kavur, A. E., Gezer, N. S., Barış, M., Aslan, S., Conze, P.-H., Groza, V., ... Selver, M. A. (2021). Chaos Dataset. Geliş tarihi gönderen <https://chaos.grand-challenge.org/Download/>
- Kim, T., Lee, K. H., Ham, S., Park, B., Lee, S., Hong, D., ... Kim, N. (2020). Active learning for accuracy enhancement of semantic segmentation with CNN-corrected label curations: Evaluation on kidney segmentation in abdominal CT. *Scientific Reports*, 10(1), 366. <https://doi.org/10.1038/s41598-019-57242-9>
- Kittipongdaja, P., ve Siriborvornratanakul, T. (2022). Automatic kidney segmentation using 2.5 D ResUNet and 2.5 D DenseUNet for malignant potential analysis in complex renal cyst based on CT images. *EURASIP Journal on Image and Video Processing*, 2022(1), 5.
- Koyuncu, H., Ceylan, R., Sivri, M., ve Erdogan, H. (2018). An Efficient Pipeline for Abdomen Segmentation in CT Images. *Journal of Digital Imaging*, 31(2), 262-274. <https://doi.org/10.1007/s10278-017-0032-0>

- Kurnaz, E., Ceylan, R., Bozkurt, M. A., Cebeci, H., ve Koplay, M. (2024). A Novel Deep Learning Model for Pancreas Segmentation: Pascal U-Net. *Inteligencia Artificial*, 27(74), 22-36. <https://doi.org/10.4114/intartif.vol27iss74pp22-36>
- Larsson, G., Maire, M., ve Shakhnarovich, G. (2017). Colorization as a proxy task for visual understanding. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 6874-6883.
- Li, X., Luo, G., ve Wang, K. (2020). *Multi-step Cascaded Networks for Brain Tumor Segmentation*. https://doi.org/10.1007/978-3-030-46640-4_16
- Liang, P., Xin, G., Yi, X., Liang, H., ve Ding, C. (2025). Automatic Pancreas Segmentation in CT Images Using EfficientNetV2 and Multi-Branch Structure. *Computers, Materials & Continua*, 83, 2481-2504. <https://doi.org/10.32604/cmc.2025.060961>
- Lim, S.-H., Kim, Y. J., Park, Y.-H., Kim, D., Kim, K. G., ve Lee, D.-H. (2022). Automated pancreas segmentation and volumetry using deep neural network on computed tomography. *Scientific Reports*, 12(1), 4075.
- Lin, H., Xiao, H., Dong, L., Teo, K. B.-K., Zou, W., Cai, J., ve Li, T. (2021). Deep learning for automatic target volume segmentation in radiation therapy: a review. *Quantitative Imaging in Medicine and Surgery*, 11(12), 4847.
- Lin, Z., Cui, Y., Liu, J., Sun, Z., Ma, S., Zhang, X., ve Wang, X. (2021). Automated segmentation of kidney and renal mass and automated detection of renal mass in CT urography using 3D U-Net-based deep convolutional neural network. *European Radiology*, 31, 5021-5031.
- Liu, F., Hernandez-Cabronero, M., Sanchez, V., Marcellin, M. W., ve Bilgin, A. (2017). The Current Role of Image Compression Standards in Medical Imaging. *Information*, C. 8. <https://doi.org/10.3390/info8040131>
- Liu, S., Yuan, X., Hu, R., Liang, S., Feng, S., Ai, Y., ve Zhang, Y. (2020). Automatic Pancreas Segmentation via Coarse Location and Ensemble Learning. *IEEE Access*, 8, 2906-2914. <https://doi.org/10.1109/ACCESS.2019.2961125>
- Liu, Xiang, Sun, Z., Han, C., Cui, Y., Huang, J., Wang, X., ... Wang, X. (2021). Development and validation of the 3D U-Net algorithm for segmentation of pelvic lymph nodes on diffusion-weighted images. *BMC Medical Imaging*, 21(1), 170. <https://doi.org/10.1186/s12880-021-00703-3>
- Liu, Xiaoming, Guo, S., Yang, B., Ma, S., Zhang, H., Li, J., ... Yang, Q. (2018). Automatic organ segmentation for CT scans based on super-pixel and convolutional neural networks. *Journal of digital imaging*, 31, 748-760.
- Ma, J., Zhang, Y., Gu, S., Zhu, C., Ge, C., Zhang, Y., ... Liu, X. (2021). Abdomenct-1k: Is abdominal organ segmentation a solved problem. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Matrone, F., Lingua, A., Pierdicca, R., Malinverni, E. S., Paolanti, M., Grilli, E., ... Landes, T. (2020). A BENCHMARK for LARGE-SCALE HERITAGE POINT

- CLOUD SEMANTIC SEGMENTATION. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. <https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-1419-2020>
- Miller, C., Portlock, T., Nyaga, D. M., ve O'Sullivan, J. M. (2024). A review of model evaluation metrics for machine learning in genetics and genomics. *Frontiers in Bioinformatics*, 4, 1457619. <https://doi.org/10.3389/fbinf.2024.1457619>
- Milletari, F., Navab, N., ve Ahmadi, S.-A. (2016). V-net: Fully convolutional neural networks for volumetric medical image segmentation. *2016 fourth international conference on 3D vision (3DV)*, 565-571. Ieee.
- Moglia, A., Cavicchioli, M., Mainardi, L., ve Cerveri, P. (2024). *Deep Learning for Pancreas Segmentation: a Systematic Review*. Geliş tarihi gönderen <http://arxiv.org/abs/2407.16313>
- Mohammadi, S. S., Wang, Y., ve Bue, A. Del. (2021). Pointview-Gcn: 3D Shape Classification With Multi-View Point Clouds. *Proceedings - International Conference on Image Processing, ICIP, 2021-Septe*, 3103-3107. <https://doi.org/10.1109/ICIP42928.2021.9506426>
- Naidu, G., Zuva, T., ve Sibanda, E. (2023). *A Review of Evaluation Metrics in Machine Learning Algorithms*. https://doi.org/10.1007/978-3-031-35314-7_2
- Pandey, M., ve Gupta, A. (2022). Tumorous kidney segmentation in abdominal CT images using active contour and 3D-UNet. *Irish Journal of Medical Science*, (0123456789). <https://doi.org/10.1007/s11845-022-03113-8>
- Qi, C. R., Su, H., Mo, K., ve Guibas, L. J. (2017a). PointNet: Deep learning on point sets for 3D classification and segmentation. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*. <https://doi.org/10.1109/CVPR.2017.16>
- Qi, C. R., Yi, L., Su, H., ve Guibas, L. J. (2017b). PointNet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in Neural Information Processing Systems, 2017-Decem(Nips)*, 5100-5109.
- Qi, Z., Dong, R., Zhang, S., Geng, H., Han, C., Ge, Z., ... Ma, K. (2024). *ShapeLLM: Universal 3D Object Understanding for Embodied Interaction*. 567. Geliş tarihi gönderen <http://arxiv.org/abs/2402.17766>
- Qureshi, T. A., Lynch, C., Azab, L., Xie, Y., Gaddam, S., Pandol, S. J., ve Li, D. (2022). Morphology-guided deep learning framework for segmentation of pancreas in computed tomography images. *Journal of Medical Imaging*, 9(2), 24002.
- Rathour, V. S., Yamakazi, K., ve Le, T. H. N. (2021). Roughness index and roughness distance for benchmarking medical segmentation. *BIOIMAGING 2021 - 8th International Conference on Bioimaging; Part of the 14th International Joint Conference on Biomedical Engineering Systems and Technologies, BIOSTEC 2021*, 82-93. <https://doi.org/10.5220/0010335500820093>

- Rayed, M. E., Islam, S. M. S., Niha, S. I., Jim, J. R., Kabir, M. M., ve Mridha, M. F. (2024). Deep learning for medical image segmentation: State-of-the-art advancements and challenges. *Informatics in Medicine Unlocked*, 47(January), 101504. <https://doi.org/10.1016/j.imu.2024.101504>
- Reed, C. J., Yue, X., Nrusimha, A., Ebrahimi, S., Vijaykumar, V., Mao, R., ... Metzger, S. (2022). Self-supervised pretraining improves self-supervised pretraining. *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2584-2594.
- Reinke, A., Tizabi, M. D., Baumgartner, M., Eisenmann, M., Heckmann-Nötzel, D., Kavur, A. E., ... Antonelli, M. (2024). Understanding metric-related pitfalls in image analysis validation. *Nature methods*, 21(2), 182-194.
- Reinke, A., Tizabi, M. D., Sudre, C. H., Eisenmann, M., Rädtsch, T., Baumgartner, M., ... Maier-hein, L. (2022). *Common Limitations of Image Processing Metrics: A Picture Story*. 1(1).
- Roth, H. R., Oda, H., Zhou, X., Shimizu, N., Yang, Y., Hayashi, Y., ... Mori, K. (2018). An application of cascaded 3D fully convolutional networks for medical image segmentation. *Computerized Medical Imaging and Graphics*, 66, 90-99. <https://doi.org/https://doi.org/10.1016/j.compmedimag.2018.03.001>
- Said, K. A. M., Jambek, A. B., ve Sulaiman, N. (2016). A study of image processing using morphological opening and closing processes. *International Journal of Control Theory and Applications*, 9(31), 15-21.
- Salehi, S. S. M., Erdogmus, D., ve Gholipour, A. (2017). Tversky loss function for image segmentation using 3D fully convolutional deep networks. *International workshop on machine learning in medical imaging*, 379-387. Springer.
- Salmanpour, M. R., Alizadeh, M., Mousavi, G., Sadeghi, S., Amiri, S., Oveisi, M., ... Hacıhaliloglu, I. (2024). *Machine Learning Evaluation Metric Discrepancies across Programming Languages and Their Components: Need for Standardization*. <https://doi.org/10.48550/arXiv.2411.12032>
- Solak, A., Ceylan, R., Bozkurt, M. A., Cebeci, H., ve Koplay, M. (2023). Adrenal Tumor Segmentation on U-Net: A Study About Effect of Different Parameters in Deep Learning. *Vietnam Journal of Computer Science*, 0, 1-25. <https://doi.org/10.1142/S2196888823500161>
- Srivastava, N. (2013). Improving neural networks with dropout. *University of Toronto*, 182(566), 7.
- Sun, J., Qing, C., Tan, J., ve Xu, X. (2023). Superpoint Transformer for 3D Scene Instance Segmentation. *Proceedings of the 37th AAAI Conference on Artificial Intelligence, AAAI 2023*, 37(c), 2393-2401. <https://doi.org/10.1609/aaai.v37i2.25335>
- Sun, P., Mo, Z., Hu, F., Song, X., Mo, T., Yu, B., ... Chen, Z. (2023). 2.5 D MFFAU-Net: a convolutional neural network for kidney segmentation. *BMC Medical Informatics and Decision Making*, 23(1), 92.

- Survarachakan, S., Prasad, P. J. R., Naseem, R., de Frutos, J. P., Kumar, R. P., Langø, T., ... Lindseth, F. (2022). Deep learning for image-based liver analysis—A comprehensive review focusing on malignant lesions. *Artificial Intelligence in Medicine*, 102331.
- Tran, S. B., Nguyen, H. T. X., Pham, H. H., ve Nguyen, H. Q. (2022). *Transparency strategy-based data augmentation for BI-RADS classification of mammograms*. 1-5. Geliş tarihi gönderen <http://arxiv.org/abs/2203.10609>
- Türk, F., Lüy, M., ve Barışçı, N. (2020). Kidney and renal tumor segmentation using a hybrid V-Net-Based model. *Mathematics*, 8(10), 1772.
- van Engelen, J. E., ve Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine Learning*, 109(2), 373-440. <https://doi.org/10.1007/s10994-019-05855-6>
- Vaswani, A., Shazeer, N. M., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... Polosukhin, I. (2017). Attention is All you Need. *Neural Information Processing Systems*. Geliş tarihi gönderen <https://api.semanticscholar.org/CorpusID:13756489>
- Walsh, J., Othmani, A., Jain, M., ve Dev, S. (2022). Using U-Net network for efficient brain tumor segmentation in MRI images. *Healthcare Analytics*, 2. <https://doi.org/10.1016/j.health.2022.100098>
- Wang, G., Li, W., Ourselin, S., ve Vercauteren, T. (2018). *Automatic Brain Tumor Segmentation Using Cascaded Anisotropic Convolutional Neural Networks*. https://doi.org/10.1007/978-3-319-75238-9_16
- Wang, Yan, Zhang, J., Cui, H., Zhang, Y., ve Xia, Y. (2021). View adaptive learning for pancreas segmentation. *Biomedical Signal Processing and Control*, 66, 102347.
- Wang, Yue, Sun, Y., Liu, Z., Sarma, S. E., Bronstein, M. M., ve Solomon, J. M. (2019). Dynamic graph cnn for learning on point clouds. *ACM Transactions on Graphics (tog)*, 38(5), 1-12.
- Wolf, D., Payer, T., Lisson, C. S., Lisson, C. G., Beer, M., Götz, M., ve Ropinski, T. (2023). Self-supervised pre-training with contrastive and masked autoencoder methods for dealing with small datasets in deep learning for medical imaging. *Scientific Reports*, 13(1), 20260.
- Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X., ve Xiao, J. (2015). 3d shapenets: A deep representation for volumetric shapes. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1912-1920.
- Xie, L., Yu, Q., Wang, Y., Zhou, Y., Fishman, E., ve Yuille, A. (2019). Recurrent Saliency Transformation Network for Tiny Target Segmentation in Abdominal CT Scans. *IEEE Transactions on Medical Imaging*, PP, 1. <https://doi.org/10.1109/TMI.2019.2930679>
- Xie, X., Li, L., Lian, S., Chen, S., ve Luo, Z. (2020). SERU: A cascaded SE-ResNeXT U-Net for kidney and tumor segmentation. *Concurrency and Computation: Practice and Experience*, 32(14), e5738.

- Xu, Y., Quan, R., Xu, W., Huang, Y., Chen, X., ve Liu, F. (2024). Advances in medical image segmentation: a comprehensive review of traditional, deep learning and hybrid approaches. *Bioengineering*, 11(10), 1034.
- Yan, Y., ve Zhang, D. (2021). Multi-scale U-like network with attention mechanism for automatic pancreas segmentation. *PLoS One*, 16(5), e0252287.
- Yang, L., ve Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316. <https://doi.org/10.1016/j.neucom.2020.07.061>
- Yang, Z., Zhang, L., Zhang, M., Feng, J., Wu, Z., Ren, F., ve Lv, Y. (2019). Pancreas segmentation in abdominal CT scans using inter-/intra-slice contextual information with a cascade neural network. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 5937-5940. IEEE.
- Yao, X., Guo, J., Hu, J., ve Cao, Q. (2019). Using deep learning in semantic classification for point cloud data. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2019.2905546>
- Zeng, W., Fan, W., Chen, R., Zheng, Z., Zheng, S., Chen, J., ... Luo, X. (2021). Accurate 3d Kidney Segmentation Using Unsupervised Domain Translation And Adversarial Networks. *2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI)*, 598-602. <https://doi.org/10.1109/ISBI48211.2021.9434099>
- Zhang, Yingxue, ve Rabbat, M. (2018). A Graph-CNN for 3D Point Cloud Classification. *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*. <https://doi.org/10.1109/ICASSP.2018.8462291>
- Zhang, Yue, Wu, J., Liu, Y., Chen, Y., Chen, W., Wu, E. X., ... Tang, X. (2021). A deep learning framework for pancreas segmentation with multi-atlas registration and 3D level-set. *Medical Image Analysis*, 68, 101884.
- Zhao, W., Jiang, D., Queralta, J. P., ve Westerlund, T. (2020). MSS U-Net: 3D segmentation of kidneys and tumors from CT images with a multi-scale supervised U-Net. *Informatics in Medicine Unlocked*, 19, 100357.
- Zhao, X., Zhang, P., Song, F., Ma, C., Fan, G., Sun, Y., ... Zhang, G. (2022). Prior Attention Network for Multi-Lesion Segmentation in Medical Images. *IEEE Transactions on Medical Imaging*, 41(12), 3812-3823.
- Zhou, Y., Xie, L., Shen, W., Wang, Y., Elliot, ve Alan. (2017). A Fixed-Point Model for Pancreas Segmentation in Abdominal CT Scans. *arXiv pre-print server*. <https://doi.org/None>