

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**H&E BOYALI HİSTOPATOLOJİK GÖRÜNTÜLERDE ÇEKİRDEK
SEGMENTASYONU İÇİN DERİN ÖĞRENMEYE DAYALI YENİ BİR
MİMARİNİN GELİŞTİRİLMESİ**

Mohamed TRAORE

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2023**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

H&E BOYALI HİSTOPATOLOJİK GÖRÜNTÜLERDE ÇEKİRDEK SEGMENTASYONU İÇİN DERİN ÖĞRENMEYE DAYALI YENİ BİR MİMARİNİN GELİŞTİRİLMESİ

Mohamed TRAORE

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Refik SAMET

Histopatolojik görüntüler, tıbbi patolojide çekirdek sayma, çekirdek yoğunluğu tahmini, çekirdek-sitoplazma oranı hesaplama ve nükleer atipi derecelendirme gibi görevleri mümkün kılarak tıbbi patolojinin önemli bir rolünü üstlenmektedir. Çekirdek segmentasyonu ve tespitinin otomatikleştirilmesi, patologların iş yükünü azaltmanın yanı sıra tanı ve tedavi planlama süreçlerini kolaylaştırarak kararların doğruluğunu ve tutarlılığını artırmaktadır. Tıbbi görüntü segmentasyonunda, özellikle histopatolojik görüntü analizinde, U-Net mimarisi mükemmel sonuçlar vererek de facto bir standart haline gelmiştir. Ancak, U-Net mimarisi, konvolüsyonlar aracılığıyla yerel bilgiyi etkili bir şekilde yakalama yeteneğine sahip olmasına rağmen, uzun mesafe bağımlılıklarını açıkça yakalama konusunda sınırlı yeteneğe sahiptir. İlk olarak diziden-diziye dönüşüm tahminleri için tasarlanan Transformerlar, küresel öz-dikkat (self-attention) mekanizmasına sahip alternatif mimariler olarak ortaya çıkmıştır. Bununla birlikte, Transformerlar düşük seviye özelliklere yeterince odaklanmama nedeniyle lokalizasyon ve ince ayrıntıların yakalanmasında eksiklikler gösterebilmektedirler. Bu tez çalışmasında, H&E boyalı histopatolojik görüntülerde çekirdeklerin doğru segmentasyonu için hem konvolüsyonel hem de Transformer bloklarını kullanan CompSegNet adlı yeni bir U-şekilli mimari önerilmiştir. Bu kapsamda önerilen konvolüsyonel bloklar, Mobil Konvolüsyon (MBConv) bloğuna, Büyüt-Filtrele-Küçült (BFK) olarak adlandırılan yeni bir alıcı alan genişletme stratejisi vasıtasıyla yeterli alıcı alan sağlanarak, ardından iyileştirilmiş küresel bağlam (GC) bloğunun entegrasyonu ile küresel bağlam modellemesi yeteneğini kazandırılarak elde edilmiştir. CompSegNet'in darboğazı, Transformer kodlayıcı bloklarını Sandglass bloğunun bir varyantına özel bir şekilde entegre eden Artık Darboğazlı Transformer (ADT) bloğundan oluşmaktadır. Ek olarak, girdi görüntülerindeki olası gürültülerin etkisini hafifletmek amacıyla U-şekilli mimarinin en üst seviyesinde gürültüye duyarlı bir kök (GDK) bloğu tasarlanmıştır. Ayrıca, mimarinin genel segmentasyon performansını iyileştirmek için ağırlıklı bir ortak kayıp fonksiyonu önerilmiştir. Önerilen CompSegNet mimarisi, nicel ve nitel değerlendirmelerde mevcut çekirdek segmentasyon yöntemlerine göre üstün performans sergilemekte ve aynı zamanda makul sayıda parametreyi korumaktadır. CompSegNet, MoNuSeg 2018 ve NuSeC 2023 veri setlerinde değerlendirildiğinde sırasıyla 0.704 ve 0.677 AJI skorlarını elde ederek, doğru çekirdek segmentasyonundaki etkinliğini kanıtlamıştır.

Temmuz 2023, 74 sayfa

Anahtar Kelimeler: Tıbbi Patoloji, H&E Boyalı Histopatolojik Görüntüler, Çekirdek Segmentasyonu, Derin Öğrenme, U-şekilli mimari, Evrişimli Sinir Ağları, Transformer

ABSTRACT

Master Thesis

DEVELOPMENT OF A NEW DEEP LEARNING ARCHITECTURE FOR NUCLEAR SEGMENTATION IN H&E HISTOPATHOLOGICAL IMAGES

Mohamed TRAORE

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Prof. Dr. Refik SAMET

Histopathological images play a crucial role in medical pathology, enabling tasks like nuclei counting, nuclei density estimation, nuclei-to-cytoplasm ratio calculation, and nuclear atypia grading. Automating nuclei segmentation and detection not only reduces pathologists' workload but also enhances the accuracy and consistency of diagnosis and treatment planning. In medical image segmentation, particularly in histopathological image analysis, the U-Net architecture has become the de-facto standard, yielding excellent results. However, while U-Net excels at capturing local information effectively through convolutions, it has limited ability to explicitly capture long-range dependencies. Transformers, initially designed for sequence-to-sequence prediction, have emerged as alternative architectures with inherent global self-attention mechanisms. Nevertheless, Transformers may lack localization abilities and fine-grained details due to insufficient focus on low-level features. In this thesis study, we propose a novel U-shaped architecture called CompSegNet, which utilizes both convolutional and transformer blocks for accurate nuclei segmentation in H&E-stained histopathological images. The proposed convolutional blocks enhance the Mobile Convolution (MBConv) block through a receptive fields enlargement strategy known as the Zoom-Filter-Rescale (ZFR) and incorporate an enhanced global context (GC) block for global context modeling. The bottleneck of CompSegNet consists of a Residual Bottleneck Transformer (RBT) block, which integrates Transformer encoder blocks in a tailored manner to a variant of the Sandglass block. Additionally, a noise-aware stem (NAS) block is designed at the highest level of the U-shaped architecture to minimize the potential impact of noise in the input images. Furthermore, a weighted joint loss function has been formulated to improve the overall segmentation performance of the architecture. The proposed CompSegNet architecture exhibits superior performance compared to existing nuclei segmentation methods in both quantitative and qualitative evaluations while maintaining a reasonable number of parameters. When evaluated on the MoNuSeg 2018 and NuSeC 2023 datasets, CompSegNet achieves a competitive and commendable AJI score of 0.704 and 0.677 respectively, demonstrating its effectiveness in accurate nuclei segmentation.

July 2023, 74 pages

Keywords: Medical Pathology, H&E Stained Histopathological Images, Nuclei Segmentation, Deep Learning, U-shaped architecture, Convolutional Neural Networks, Transformer

TEŞEKKÜR

Tez çalışmam sürecindeki yönlendirmeleri ve değerli katkıları için başta danışman hocam sayın Prof. Dr. Refik Samet olmak üzere, Assoc. Prof. Dr. Emrah Haçer ve doktora adayı Zeynep Yıldırım ile birlikte tüm TÜBİTAK 1001 (proje no: 121E379) proje üyelerine en içten teşekkürlerimi sunarım.

Mohamed TRAORE
Ankara, Temmuz 2023

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK	i
ÖZET	ii
ABSTRACT	iii
TEŞEKKÜR	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	5
2.1 Geleneksel Yöntemlerle Çekirdek Segmentasyonu	5
2.2 Derin Öğrenme Mimarileri ile Çekirdek Segmentasyonu	6
2.3 Mobil Ağlar.....	10
2.4 Darboğazlı Transformerlar.....	11
3. COMPSEGNET MİMARİSİNİN GELİŞTİRİLMESİ	15
3.1 CompSegNet Mimarisi	15
3.2 CompSegNet Mimarisinde Kullanılan Temel Bloklar	15
3.2.1 Gürültüye duyarlı kök bloğu	18
3.2.2 CompSeg ve genişletilmiş CompSeg blokları	19
3.2.3 Artık Darboğazlı Transformer bloğu.....	27
3.3 Kayıp Fonksiyonu	34
3.4 Değerlendirme Metrikleri	35
4. COMPSEGNET MİMARİSİNİN UYGULANMASI	37
4.1 Veri Setleri	37
4.1.1 MoNuSeg 2018.....	37
4.1.2 NuSeC 2023.....	38
4.2 Veri Setlerinin Ön İşlenmesi	40
4.3 Donanım ve Yazılım Bilgileri.....	42
4.4 CompSegNet Mimarisi	42
5. BULGULAR ve TARTIŞMALAR	48
5.1 Hafif Ağın Bulguları ve Tartışması	48
5.2 CompSegNet Mimarisinin Bulguları ve Tartışması	52
5.3 Kayıp Fonksiyonundaki Parametrenin Etkisi.....	57
5.4 Son Çalışmalarla Karşılaştırmalar.....	58
6. SONUÇLAR	61
KAYNAKLAR	66
ÖZGEÇMİŞ.....	73

SİMGELER DİZİNİ

FLOPS	Floating Point Operations Per Second (Saniye Başına Kayan Nokta İşlemleri)
GB	Gigabyte (Gigabayt)
GHz	Gigahertz (Gigahertz)
ms/küme	Görüntü kümesi başına geçen milisaniye
ms/görüntü	Görüntü başına geçen milisaniye

Kısaltmalar

ADT	Artık Darboğazlı Transformer
AEP	Attention Encoding Path (Dikkat Kodlama Yolu)
AJI	Aggregated Jaccard Index (Toplanmış Jaccard Endeksi)
ASM	Attention Skip Module (Dikkat Atlamalı Modülü)
ASM	Atrous Spatial Pyramid Pooling (Boşluklu Sınırlı Hiyerarşik Alan Havuzu)
ASPP	Atrous Spatial Pyramid Pooling (Atrous Uzamsal Piramit Havuzlama)
BCE	Binary Cross Entropy (İkili Çapraz Entropi)
BFK	Büyüt-Filtrele-Küçült
BoT	Bottleneck Transformer (Darboğazlı Transformer)
CLAHE	Contrast Limited Adaptive Histogram Equalization (Kontrast Sınırlı Uyumlu Histogram Eşitleme)
CNN	Convolutional Neural Network (Evrışimli Sinir Ağ)
CPU	Central Processing Unit (Merkezi İşlem Birimi)
Cseg	Comp Seg
ECseg	Extended Comp Seg (Genişletilmiş Comp Seg)
FFN	Feedforward Neural Network (İleri Beslemeli Ağ)
GC	Global Context (Küresel Bağlam)
GDK	Gürültüye Duyarlı Kök
GeLU	Gaussian Error Linear Unit (Gaussian Hata Lineer Ünitesi)
GPU	Graphics Processing Unit (Grafik İşlemci Birimi)
H&E	Hematoxylin and Eosin (Hematoksilen ve Eozin)
IGC	Improved Global Context (İyileştirilmiş Küresel Bağlam)
MBConv	Mobile Convolution (Mobil Konvolüsyon)
MHSA	Multi-Head Self-Attention (Çok Kafalı Öz-Dikkat)
MiDeSeC	Mitoz Tespiti, Segmentasyonu ve Sınıflandırması
MoNuSeg	Multi-Organ Nucleus Segmentation (Çoklu Organ Nükleer Segmentasyonu)
MiDeSeC	Mitosis Detection, Segmentation and Classification (Mitoz Tespiti, Segmentasyonu ve Sınıflandırması)
NuSeC	Nuclei Segmentation and Classification (Çekirdek Segmentasyonu ve

	Sınıflandırma)
RAM	Random Access Memory (Rastgele Erişimli Hafıza)
RGB	Red-Green-Blue (Kırmızı-Yeşil-Mavi)
ReLU	Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
SE	Squeeze-and-Excitation (Sıkma-ve-Uyarma)
SNL	Simplified nonlocal (Basitleştirilmiş Yerel Olmayan)
TIF	Transformer Interactive Fusion (Transformer Etkileşimli Füzyon)
TMA	Tissue Microarray (Doku Mikrodizisi)
TÜBİTAK	Türkiye Bilimsel ve Teknolojik Araştırma Kurumu

ŞEKİLLER DİZİNİ

Şekil 3.1 Önerilen CompSegNet'in genel mimarisi.....	16
Şekil 3.2 GDK bloğunun ayrıntılı yapısı.....	19
Şekil 3.3 MBConv bloğunun ayrıntılı yapısı.....	21
Şekil 3.4 CSeg bloğunun ayrıntılı yapısı.....	24
Şekil 3.5 IGC (solda) ve ESeg (sağda) bloklarının yapısı.....	26
Şekil 3.6 Sandglass bloğunun genel yapısı.....	28
Şekil 3.7 Transformer bloğunun genel yapısı	30
Şekil 3.8 ADT bloğunun genel yapısı.....	32
Şekil 4.1 MoNuSeg 2018 veri setine ait örnek görüntüler.....	38
Şekil 4.2 NuSeC veri setine ait örnek görüntüler.....	39
Şekil 4.3 MoNuSeg 2018 veri setinden normalize edilmiş görüntü örnekleri.....	41
Şekil 4.4 NuSeC 2023 veri setinden normalize edilmiş görüntü örnekleri.....	41
Şekil 5.1 MoNuSeg 2018 veri setinde farklı hafif ağ varyantlarıyla elde edilen segmentasyon sonuçlarına ait örnek görüntüler ve bu sonuçların nicel karşılaştırması.....	51
Şekil 5.2 NuSeC 2023 veri setinde farklı hafif ağ varyantlarıyla elde edilen segmentasyon sonuçlarına ait örnek görüntüler ve bu sonuçların nicel karşılaştırması.....	52
Şekil 5.3 MoNuSeg 2018 veri setinde CompSegNet mimarisinin segmentasyon sonuçlarına örnek görseller.....	56
Şekil 5.4 NuSeC 2023 veri setinde CompSegNet mimarisinin segmentasyon sonuçlarına örnek görseller.....	56
Şekil 5.5 CompSegNet ile MoNuSeg2018 yarışma sonuçlarının karşılaştırması.....	60

ÇİZELGELER DİZİNİ

Çizelge 3.1 CompSegNet'in ayrıntılı yapısı	17
Çizelge 3.2 CSeg bloğunun parametre ve girdi / çıktı detayları.....	24
Çizelge 3.3 ADT bloğunun ayrıntılı parametre ve girdi/çıktı boyutları.....	33
Çizelge 4.1 Hafif ağ varyantlarının kullandığı temel bloklar.....	43
Çizelge 4.2 Hafif ağın parametre ayarları.....	44
Çizelge 4.3 CompSegNet mimarisi varyantlarının kullandığı temel bloklar.....	45
Çizelge 4.4 CompSegNet mimarilerinin parametre ayarları.....	46
Çizelge 5.1 Hafif ağ varyantlarının değerlendirme metrik sonuçları.....	49
Çizelge 5.2 Hafif ağ varyantlarında kullanılan kaynaklar.....	49
Çizelge 5.3 CompSegNet mimarisinin varyantlarının değerlendirme metrik sonuçları	53
Çizelge 5.4 CompSegNet mimarisinin varyantlarında kullanılan kaynaklar.....	53
Çizelge 5.5 Kayıp fonksiyonundaki parametrelerin ayar sonuçları.....	58
Çizelge 5.6 MoNuSeg 2018 veri setinde CompSegNet mimarisinin diğer çalışmalarla karşılaştırılması.....	59

1. GİRİŞ

Hematoksilen ve eozin (H&E) boyalı histopatolojik görüntülerdeki çekirdekler birçok hastalığın teşhis ve karakterizasyonunda önemli rol oynamaktadır. Çekirdekler, dokunun morfolojisi ve düzenlenmesi hakkında önemli bilgiler sağlayan en belirgin hücresel yapılardır (Kimura ve Yonemura 1991). Çekirdeklerin önemi şu örneklerle açıklanabilir (Basu vd. 2023). İlk olarak, çekirdekler genellikle kanserleri teşhis etmek ve sınıflandırmak için kullanılmaktadır. Çekirdeklerin boyutu, şekli ve düzenlenmesi, tümörün agresifliği ve evresini belirleyebilmektedir. İkinci olarak, çekirdekler aracılığıyla hastalıkları ayırt etmek mümkündür. Örneğin, iltihabi koşullar altında çekirdekler belirli bir desende bir araya gelebilir ve hastalığı işaret edebilir. Üçüncü olarak, çekirdeklerin morfoloji ve düzenlenmesindeki değişiklikler, tedaviye verilen bir yanıtı gösterebilmektedir. Örneğin, tümörün kemoterapi veya radyasyon terapisine yanıtı, çekirdeklerin boyut ve şeklindeki değişikliklerle belirlenebilmektedir. Son olarak, çekirdekler, segmentasyon ve sınıflandırma gibi görüntü analizi görevlerinde yaygın olarak kullanılmaktadır. Görüntülerdeki çekirdeklerin; görüntü işleme, yapay zeka ve benzeri tekniklerle tespit edilmesi, incelenmesi ve karakterize edilmesi, patologların gerçekleştirdiği bazı görevlerin otomatikleştirilmesini sağlayarak iş yüklerini azaltmaktadır. Ayrıca tedavi planlama süreçlerini kolaylaştırmakta ve alınan kararların doğruluğunu ve tutarlılığını artırmaktadır. Genel olarak H&E histopatolojik görüntülerdeki çekirdekler, morfoloji ve doku düzenlenmesi hakkında kritik bilgiler sağlayarak teşhis sürecinin önemli bir parçası olarak hizmet etmektedir (Jevtic vd. 2023).

Histopatolojik görüntülerdeki çekirdeklerin tanımlanması ve çıkarılması için literatürde çeşitli yöntemler önerilmiştir (Hancer vd. 2023). Bu yöntemler genellikle geleneksel yöntemler ve öğrenme tabanlı yöntemler olmak üzere iki ana kategoriye ayrılabilir. Geleneksel yöntemler genellikle eşikleme, havza tabanlı ve graf tabanlı gibi yöntemler içermektedir. Eşikleme yöntemlerinde (Gadgil vd. 2016, Phoulady vd. 2016), bir eşik değeri belirlenerek çekirdeklerin arka plandan ayrıştırılması sağlanmaktadır. Bu eşik değeri, görüntüdeki çekirdeklerin renk, şekil ve yoğunluk gibi özelliklerine bağlı olarak manuel veya otomatik olarak seçilmektedir.

Daha sonra, erozyon ve genişleme gibi morfolojik operasyonlar uygulanarak ayrıştırılan çekirdeklerin şekli ve sınırları belirginleştirilmektedir. Havza temelli yöntemlerde (Veta vd. 2011, 2013), çekirdeklerin segmentasyonu için havza algoritması gibi matematiksel teknikler kullanılmaktadır. Havza algoritmasında, görüntü bir topografik yüzey olarak ele alınmakta ve her piksel bir toplama havzasına atanmaktadır. Daha sonra, bu toplama havzaları kullanılarak çekirdekler segmente edilmektedir (bölütlenmektedir). Graf temelli yöntemlerde (Xing vd. 2011, Faridi vd. 2016) ise, çekirdekler, görüntünün graf temsillerine dayanarak segmente edilmektedir. Pikseller, bir graf içinde düğümler olarak temsil edilirken, kenarlar pikseller arasındaki ilişkileri temsil eder. Graftaki çekirdeklerin tespit edilmesi için minimum kesim veya maksimum akış gibi teknikler kullanılmaktadır. Geleneksel yöntemler, bazı uygulamalarda yüksek performans gösterse de çekirdek segmentasyonunda görüntülerdeki gürültü, arka plan heterojenliği, çekirdeklerin renkleri, şekilleri, boyutları, konumları ve yoğunlukları gibi faktörlere bağlı olarak önemli sınırlamalar gösterebilmektedir (Yıldırım vd. 2022).

Öğrenme tabanlı yöntemler ise, çekirdeklerin ve arka planın farklı özelliklerini etkili bir şekilde öğrenerek yeni ve görülmemiş görüntü örnekleri için genelleme yapabilme yeteneğine sahip yöntemlerdir. Bu yetenekleri sayesinde geleneksel yöntemlerin sınırlamalarını etkili bir şekilde ele almaktadır. Bu durum, özellikle büyük miktarlarda histopatolojik görüntülerin analiz edilmesi gereken klinik ortamlarda önem arz etmektedir. Güncel literatürde, derin öğrenmeye dayalı yöntemler histopatolojik görüntülerde çekirdek segmentasyonu için en yaygın kullanılan öğrenme tabanlı yöntemlerdir. Bu yöntemler, karmaşık ilişkileri modelleme kabiliyetleri, uçtan uca öğrenme yetenekleri, yüksek genelleme yapma kapasiteleri, adaptif yetenekleri ve hiyerarşik özellik öğrenimi gibi özellikleri nedeniyle tercih edilmektedir. Derin öğrenmeye dayalı segmentasyon mimarileri arasında, özellikle histopatolojik görüntülerde çekirdek segmentasyonu gibi medikal görüntülerde segmentasyon görevleri için en yaygın ve öne çıkan mimari, U-Net (Ronneberger vd. 2015) mimarisidir. U-Net mimarisinin çekirdek segmentasyonundaki umut verici performansına rağmen, aşırı uyma (overfitting), sınırlı alıcı alanı (receptive field) ve görüntü kalitesine duyarlılık gibi sorunları bulunmaktadır (Wang vd. 2021, Abdel-Nabi vd. 2023). Araştırmacılar, U-Net'in performansını artırmak için birçok iyileştirme

uygulamış olsalar da, çalışmalar henüz tamamlanmış değildir (Nodirov vd. 2022, Protonotarios vd. 2022, Albishri vd. 2022). Başka bir deyişle, histopatolojik görüntülerde çekirdek segmentasyonu için rekabetçi ve pratik bir mimariye olan ihtiyaç hala devam etmektedir.

Bu tez çalışmasının genel amacı, H&E boyalı histopatolojik görüntülerde çekirdek segmentasyonu için derin öğrenmeye dayalı yeni bir mimari geliştirmektir. Bu amaç doğrultusunda, H&E boyalı histopatolojik görüntülerde çekirdek tespiti ve segmentasyonu ile ilgili güncel literatür taranmış ve farklı çalışmaların iyi ve eksik yönleri tespit edilmiştir. Ayrıca derin öğrenmeye dayalı bilgisayarla görme alanındaki diğer son teknoloji çalışmaları incelenmiş ve çekirdek segmentasyonu için kullanılabilecek ve uyarlanabilecek yönleri tespit edilmiştir. Bu bilgiler ışığında, karmaşık sahnelerde bile çekirdeklerin yüksek doğrulukla segmentasyonunu sağlamak için yerel ve global bilgileri etkili bir şekilde entegre eden CompSegNet adında yeni bir U-şekilli ağ mimarisi geliştirilmiştir.

CompSegNet mimarisinin geliştirilmesinde, U-Net mimarisi temel alınmıştır. Mimarinin kodlayıcı (encoder) ve kod çözücü (decoder) yollarında kullanılmak üzere MBConv ve GC bloklarından faydalanarak CompSeg (CSeg) ve genişletilmiş CompSeg (ECSeg) adında yeni temel bloklar geliştirilmiştir. CSeg bloğu, Büyüt-Filtrele-Küçült (BFK) yöntemiyle MBConv bloğuna yeterli alıcı alan sağlayarak U-Net mimarisinin sınırlı alıcı alan sorununu etkili bir şekilde ele almaktadır. ECSeg bloğu ise, CSeg bloğuna GC bloğu entegre edilmesiyle CSeg bloğunun küresel bağlam modellemesi yeteneğini artırmaktadır. Mimaride, kodlayıcı ve kod çözücü yollarını etkili bir şekilde bağlamak için köprü görevini gören Artık Darboğazlı Transformer (ADT) bloğu önerilmiştir. ADT bloğu, Sandglass bloğunun bir varyantına Transformer kodlayıcı bloklarını uygun bir şekilde entegre ederek, konvolüsyonel ve dikkat mekanizmalarını kullanarak kod çözücü yoluna ayrıntılı yüksek çözünürlüklü mekansal bilgileri ve zengin küresel bağlamsal bilgileri sağlamaktadır. U-Net gibi atlama bağlantılarını (skip connections) kullanan mimarilerin en yaygın sorunlarından biri girdi görüntülerinde olası gürültülerin atlama bağlantıları yoluyla kod çözücü yoluna iletilerek mimarilerinin genel performansını etkilemesidir. CompSegNet mimarisi, bu sorunu hafifletmek için

gürültüye dayalı kök (GDK) olarak adlandırılan yeni bir blok kullanmaktadır. CompSegNet mimarisinin diğer bir yenilikçiliği ise kayıp fonksiyonu olarak ikili çapraz entropi (BCE) ve Dice kayıp fonksiyonlarının avantajlarını birleştiren ağırlıklı ortak bir kayıp fonksiyonu kullanmasıdır.

Önerilen CompSegNet mimarisi, MoNuSeg 2018 ve NuSeC 2023 histopatolojik veri setlerinde eğitilmiş ve literatürde en çok bilinen derin öğrenme değerlendirme metrikleri kullanılarak değerlendirilmiştir. CompSegNet bu veri setlerinde, sırasıyla 0.704 ve 0.677 AJI skoru elde ederek doğru çekirdek segmentasyonundaki etkinliğini kanıtlamıştır. CompSegNet, literatürdeki mevcut çekirdek segmentasyon yöntemlerinin hem niceliksel hem de niteliksel olarak üzerine çıkmaktadır. Ayrıca, CompSegNet iyi organize edilmiş tasarımı sayesinde ek bloklara rağmen optimum bir parametre sayısını korumaktadır.

Sonraki bölümlerde, tez çalışması kapsamında yapılan literatür taramasıyla birlikte, çekirdek segmentasyonu için önerilen CompSegNet mimarisinin geliştirilmesi ve uygulanması ele alınmakta olup, elde edilen bulgular, yapılan tartışmalar ve sonuçlar da sunulmaktadır.

2. LİTERATÜR TARAMASI

Bu bölümde, öncelikle çekirdek segmentasyonu için geleneksel yöntemler ve ardından derin öğrenme tabanlı mimariler hakkında genel bir literatür özeti sunulmaktadır. Daha sonra, CompSegNet mimarisinde kullanılan temel bloklar olarak mobil konvolüsyon mimarileri ile ilgili literatür çalışmaları ele alınmaktadır. Darboğazlı transformer bloklarıyla ilgili yapılan çalışmalara da genel bir bakış sunulmaktadır. Son olarak, bu çalışmaların genel bir özeti verilmekte, eksik yönleri belirtilmekte ve bu tez çalışmasında bu eksikliklerin ele alınması için önerilen yöntemlerden bahsedilmektedir.

2.1 Geleneksel Yöntemlerle Çekirdek Segmentasyonu

Geleneksel yöntemler, çekirdek segmentasyonu için literatürde yaygın olarak kullanılmaktadır. Bu yöntemler, eşikleme (Gadgil vd. 2016, Phoulady vd. 2016), havza tabanlı (Veta vd. 2011, 2013), graf tabanlı (Xing vd. 2011, Faridi vd. 2016), istatistiksel model (Xu vd. 2011, Taheri vd. 2017) ve aktif konturlar (Naik vd. 2008, Ali ve Madabhushi 2012) gibi segmentasyon yöntemlerini içermektedir. Eşikleme yöntemi, bu yöntemler arasında en basit ve uygulanması en kolay olanıdır. Ancak, piksel değerlerine dayandığı için görüntü gürültüsüne oldukça hassastır. Havza tabanlı yöntemler ise tıbbi görüntü analizinde yaygın olarak kullanılıyor olsa da bu yöntemler genellikle aşırı bölütlenme sorununa eğilimlidir. Yang vd. (2006), zaman aralıklı mikroskopi görüntülerinde çekirdek segmentasyonu için işaretleyici kontrollü havza yöntemini önermişlerdir. Çalışmalarında, komşu kareler arasında bağlam bilgisinden yararlanarak aşırı bölünmüş ve yetersiz bölünmüş hücreler için düzenlemeler yapmışlardır. Ayrıca, takip işlemi için ortalama kayma ve Kalman filtresinin bir kombinasyonunu kullanmışlardır. Jierong ve Rajapakse (2009) ise havzalar için çekirdek işaretleyicilerini bulmak üzere adaptif bir H-minima dönüşümünü tanıtmışlar. İşaretleyici tabanlı yöntemler, doğru çekirdek tespitine dayanmaktadır ve belirli uygulamalara büyük ölçüde bağımlıdır, bu nedenle histopatolojik gibi büyük ölçekli görüntülere uygulamaları oldukça zor olabilmektedir.

Aktif kontur (AK), hastalık bölgelerini tespit etmek için tıbbi görüntü segmentasyonunda yaygın olarak kullanılan bir yöntemdir. Örneğin, Ali ve Madabhushi (2012), bölge, sınır ve şekil bilgilerini AK modeline entegre ederek meme ve prostat biyopsi örneklerinin dijital histopatolojik görüntülerinde çekirdek ve glandları segmente etmişlerdir. Xing vd. (2016), meme kanseri histopatoloji görüntülerini segmente etmek için derin öğrenme ve AK modelinin bir kombinasyonunu sunmuştur. Bu çalışmada derin öğrenme tekniğinin AK modeli için önceden şekil bilgisi olarak bir olasılık haritası sağladığını belirtmişlerdir. Xu vd. (2017), bölge tabanlı AK modelinin enerji terimine Markov rastgele alan önceliğini dahil ederek glandların arka plandan ayrılmasını sağlamışlardır. AK tabanlı segmentasyon yöntemlerinde, istenen kontur şekillerinin önceden belirlenmesi gerekmektedir. Bu nedenle, bu yöntemler histopatolojik görüntülerin segmentasyonunda önemli gelişmeler sağlasa da çekirdeklerin farklı şekillere sahip olabilmesi nedeniyle uygulamaları oldukça zorlu ve meşakkatlidir.

Geleneksel yöntemler genellikle el yapımı özelliklere dayanmaktadır. Bu yöntemlerin çekirdek segmentasyonu için temel kısıtlamaları, parametre ayarlarına ve özel çekirdek yapılarına duyarlı olmalarıdır. Bu nedenle çekirdeklerin doğru ve etkili segmentasyonu için adaptif, otomatik öğrenme ve genelleme yeteneklerine sahip yöntemlere ihtiyaç duyulmaktadır.

2.2 Derin Öğrenme Mimarileri ile Çekirdek Segmentasyonu

Derin öğrenme yöntemleri, medikal görüntü analizi başta olmak üzere bilgisayarla görme, doğal dil işleme, ses işleme gibi birçok farklı alanda karmaşık ilişkileri modelleme ve yüksek genelleme yetenekleri sayesinde büyük ilerlemelerin kaydedilmesine olanak sağlamıştır. Bu alt bölümde, tez çalışmasına ışık tutan güncel literatürde çekirdek segmentasyonu ile ilgili geliştirilen mimarilerinin özeti sunulmaktadır.

Ronneberger vd. (2015), elektron mikroskopik yığınlarda nöron yapılarının segmentasyonu ve diferansiyel interferans kontrast mikroskobu görüntülerinde HeLa

hücrelerinin tespiti için derin öğrenmeye dayalı yeni bir mimari olan U-Net'i önermişlerdir. U-Net, girdi görüntülerini kodlayarak gerekli özellikleri temsil etmek için bir kodlayıcı yolu ve ardından kodlanmış özellikleri çözerek çıktı maskelerini oluşturmak için bir kod çözücü yolunu içeren U-şekilli bir mimaridir. Ayrıca U-Net, görüntü özelliklerinin konumlarını korumak için atlama bağlantıları kullanmaktadır. U-Net mimarisi, tıbbi görüntü segmentasyonu görevlerinde başarılı olmasına rağmen, aşırı uyum, sınırlı alıcı alanı ve görüntü kalitesine duyarlılık gibi bazı zorluklarla karşılaşmaktadır. Son zamanlarda, literatürde U-Net'in farklı sınırlamalarını ele almak için birçok yöntem önerilmiştir. Bu yöntemler genellikle U-Net'in diğer derin öğrenme mimarileriyle birleştirilmesini içermektedir. Bu yöntemler, çekirdek segmentasyonu da dahil olmak üzere çeşitli bilgisayarla görme görevlerinde yaygın olarak kullanılmaktadır. Bu karma modeller (Alom vd. 2018, Graham vd. 2019, Zeng vd. 2019, Jung vd. 2019, Wan vd. 2020, Chen vd. 2021, Aatresh vd. 2021, Wang vd. 2022, Kiran vd. 2022), genellikle bireysel bileşenlerinden daha iyi performans göstermekte ve U-Net mimarisinin çok yönlülüğünü ve uyarlanabilirliğini göstermektedir. Örneğin, Wan vd. (2020), histopatolojik görüntülerde çekirdek segmentasyonu için U-Net'i ASPP (Atrous Uzamsal Piramit Havuzlama - Atrous Spatial Pyramid Pooling) modülüyle birleştirerek U-Net mimarisindeki sınırlı alıcı alan sorununu etkili bir şekilde ele almışlardır. Ayrıca, ASPPU-Net adını verdikleri mimarinin eğitiminde sınıf dengesizliği sorununu hafifletmek için Dice kayıp fonksiyonuyla ağırlıklı BCE kayıp fonksiyonunu kullanmışlardır. ASPPU-Net, çekirdek segmentasyonunda son teknoloji bir performans sergilemiştir. Chidester vd. (2019), U-Net mimarisinin çekirdek segmentasyonu görevinde etkisini artırmak için U-Net mimarisine döndürme eşdeğerliğini kodlamış ve atlama bağlantılarında kullanılmak üzere özel artık bloklar önermişlerdir. Ayrıca aynı çalışma kapsamında histopatolojik görüntülere özgü yeni veri artırma yöntemlerini tanıtmışlardır. Böylece daha iyi bir performans elde edebilmişlerdir. Bu çalışma, U-Net mimarisinin genelleme yeteneğini artırmış ve aşırı uyma sorununu hafifletmiştir. Bu çalışmalar, U-Net mimarisine ek modüllerin dahil edilmesinin etkinliğini göstermektedir.

Çekirdek segmentasyonunda karşılaşılan önemli bir zorluk da çakışan çekirdeklerle uğraşmak ve boyut, şekil ve görünüm açısından değişkenlikleri ele almaktır. Bu sorunu

çözmek için birçok yöntem, dikkat mekanizmaları veya Mask-RCNN (He vd. 2017) gibi örneğe duyarlı segmentasyon yöntemleri gibi ek modüller ekleyerek, uzun mesafe bağımlılıkları yakalamayı ve performansı artırmayı hedeflemiştir.

Lal vd. (2020), H&E boyalı prostat histopatolojik görüntülerinde çekirdek segmentasyonunu etkin bir şekilde ele alan NucleiSegNet adlı bir mimari önermiştir. Bu mimari, örtüşen çekirdekler, değişen boyutlar, şekiller ve görünümüler gibi zorlukları başarılı bir şekilde ele almaktadır. NucleiSegNet; güçlü artık bloklar, darboğaz blokları ve dikkat çekici kod çözücü bloklarını içermektedir. Ayrıca, mimarinin genel performansını artırmak için BCE ve Dice kayıp fonksiyonlarının harmonik ortalamasını alan yeni bir kayıp fonksiyonu da tanımlanmıştır. DEAU (Wang vd. 2022), çekirdek segmentasyonu için geleneksel bir U-Net modeline dikkat kodlama yolu (Attention Encoding Path (AEP)) eklemiş ve anlamlı özellikler öğrenmek için dikkat önceliğini girdi olarak kullanmıştır. AEP, basit kodlama yolunda olduğu gibi aynı boyutlarda işlem yapar ve her iki özellik haritası da çeşitli ağ derinliklerinde dikkat atlamalı modülde (attention skip module (ASM)) kullanılmaktadır. EU-Net (Kiran vd. 2022) çekirdek segmentasyonunda daha yüksek bir performans sergilemek için U-Net mimarisine Sıkıştırma ve Uyarma (squeeze-and-excitation (SE)) bloklarını adapte ederek ağır gereksiz özelliklerini baskılamasını, yararlı özelliklere odaklanmasını ve uygun bir şekilde yeniden kalibre etmesini sağlamıştır. Wei vd. (2019), diğer mimarilerden farklı olarak çekirdek sınıflandırma ve segmentasyonunda çekirdeklerin örtüşme ve şekil değişkenliği sorunlarını ele almak için çekirdek piksellerinin merkezine olan dikey ve yatay mesafelerini içeren örnek-zengin bilgilerini kullanan yeni bir evrişimli sinir ağ mimarisi olan HoverNet'i sunmuşlardır. HoverNet, artıklık birimlerinden oluşan bir kodlayıcı ve üç farklı kod çözücülerden oluşan bir yapıya sahiptir. İlk kod çözücü, pikselleri çekirdek veya arka plan olarak sınıflandırırken, ikinci kod çözücü yatay ve dikey haritalarını oluşturmak için kullanılmaktadır. Üçüncü kod çözücü ise pikselleri çekirdek türlerine göre sınıflandırmaktadır. Mimari, her bir kod çözücü için ayrı bir kayıp fonksiyonu kullanmaktadır. Mimarinin çıkışında, işaretleyici kontrollü havza yöntemiyle kod çözücülerinin çıktılarını birleştirerek çekirdeklerin bireysel (instance) segmentasyonu gerçekleştirilmektedir. HoverNet, çekirdek sınıflandırma ve

segmentasyonunda iyi performans göstermesine rağmen, çok sayıda parametreye sahip olması nedeniyle yüksek donanım kaynakları gerektirmektedir.

Son yıllarda biyomedikal görüntü analizi de dahil olmak üzere birçok bilgisayarla görme çalışması, yerel özelliklerin etkin bir şekilde çıkarılmasını sağlamak ve aynı zamanda uzun mesafe bağımlılıkları yakalamak için evrişim sinir ağı mimarilerini Transformer mimarileriyle birleştirerek önemli sonuçlar elde etmiştir. Örneğin, TransUNet (Chen vd. 2021) mimarisi, U-Net ve Transformer mimarilerini birleştirerek tıbbi görüntü segmentasyonunda rekabetçi sonuçlar elde etmiştir. Bu entegre mimaride, U-Net'in kodlayıcı yolunda yerel özelliklerin etkili bir şekilde çıkarılması için CNN tabanlı bloklar kullanılırken, Transformer blokları kullanılarak uzak bağımlılıklar modellenmektedir. Kod çözücü yolunda ise bu bilgiler yüksek çözünürlüklü CNN özellik haritalarıyla birleştirilerek sonuç maskeleri oluşturulmaktadır. TransUNet, tıbbi görüntü segmentasyonunda başarılı sonuçlar elde etmek için güçlü bir seçenek olarak öne çıkmaktadır. TransResUNet (Tomar vd. 2022) mimarisi, TransUNet ile aynı yapıda olup CNN blokları olarak artık bloklarını kullanmıştır. Ayrıca, TransResUNet, darboğaz bölgesinde Transformer bloklarını ve ASPP modülünü paralel olarak kullanarak çıktı özellik haritalarını kod çözücüye iletmektedir. Bu mimari, polip görüntülerinin segmentasyonunda iyi bir performans sergilemiştir. TransResUNet (Tomar vd. 2022) mimarisi ise TransUNet farklı olarak CNN bloğu olarak artık blokları kullanmıştır. Ayrıca mimarinin darboğazında Transformer blokları ve ASPP modülünü paralel kullanmış ve çıktı özellik haritasını kod çözücüye beslemiştir. Bu mimari, polip görüntülerinin segmentasyonunda iyi bir performans göstermiştir. Başka bir örnek ise, Lin vd. (2021) tarafından tanıtılan DS-TransUNet adlı mimaridir. DS-TransUNet, hem kodlayıcı hem de kod çözücü kısımlarında hiyerarşik Swin Transformer (Liu vd. 2021)'ın avantajlarını birleştiren U-şekilli bir mimaridir. Bu mimari, çift ölçekli kodlayıcı alt ağları kullanarak farklı anlamsal ölçeklerin kaba ve ince taneli özelliklerini çıkarmakta ve bu özellikler arasında küresel bağımlılıkların kurulmasını sağlamak için Transformer etkileşimli füzyon (Transformer interactive fusion (TIF)) modülünü kullanmaktadır. Kod çözücü bölümünde ise Swin Transformer bloğu kullanılarak yukarı örnekleme sürecinde uzun menzilli bağlamsal bilgiler yakalanmaktadır. Yapılan

deneysel sonuçlar, DS-TransUNet'in farklı tıbbi görüntü segmentasyon görevlerinde mevcut yöntemlere kıyasla üstün performans sergilediğini göstermiştir.

Genel olarak, derin öğrenme mimarileri çekirdek segmentasyonunda önemli ilerlemeler sağlamış olup son teknoloji yöntemler geniş bir veri setinde yüksek doğruluk ve genelleme yeteneği sergilemektedir. Bu, çekirdeklerin doğru segmentasyonunun teşhis ve tedavi planlaması için önemli olduğu tıbbi görüntüleme ve patoloji gibi çeşitli alanlarda potansiyel uygulamalara sahiptir.

2.3 Mobil Ağlar

Kaynak kısıtlaması olan cihazlar ve mobil uygulamalar için uygun, daha verimli ve hafif evrimsel sinir ağı mimarilerinin geliştirilmesinde son zamanlarda çok büyük ilerlemeler kaydedilmiştir. Tıbbi görüntüleme alanında çekirdek segmentasyonu için derin öğrenme mimarilerinde omurga mimarileri olarak mobil ağların (Zhang vd. 2018, Zhang vd. 2018, Tan vd. 2019, Mehta vd. 2020) kullanımı giderek artmaktadır. Bu, MobileNetV2 (Sandler vd. 2018) ve MobileNetV3 (Howard vd. 2019) gibi modellerin yüksek hesaplama verimliliği ve düşük model karmaşıklığı ile yüksek doğruluk sağlama yeteneklerinden kaynaklanmaktadır. MobileNetV2 ve MobileNetV3 mimarileri, hesaplama maliyetini azaltmak ve doğruluğu artırmak için derinlemesine ayrılabilir konvolüsyonlar ve doğrusal darboğaz katmanları gibi çeşitli teknikler kullanırlar. MobileNetV3 ayrıca parametre sayısını azaltan ve özellik temsiliyi iyileştiren çoklu aktivasyon ve hard-swish aktivasyon fonksiyonları içermektedir. Ayrıca, özellik temsiliyi iyileştirmek ve ağı ayırt edici gücünü artırmak için SE kullanılmaktadır. MobileNeXt (Zhou vd. 2020), MobileNetV2 ve diğer son teknoloji sinir ağı mimarilerinin fikirleri üzerine inşa edilen yeni bir sinir ağı mimarisidir. MobileNeXt'in ana yeniliklerinden biri, yüksek doğruluğu korurken hesaplama verimliliğini en üst düzeye çıkarmak için tasarlanmış hiyerarşik bir blok yapısının kullanılmasıdır. Hiyerarşik blok yapısı, her biri belirli bir hesaplama görevi için optimize edilmiş birkaç yapı taşından oluşmaktadır. Bu yapı taşları daha sonra tam sinir ağı mimarisini oluşturmak için hiyerarşik bir şekilde kullanılmaktadır. MobileNeXt'in bir diğer önemli yeniliği de H-swish aktivasyon fonksiyonu adı verilen yeni bir doğrusal olmayan

aktivasyon fonksiyonu biçiminin kullanılmasıdır. Bu aktivasyon fonksiyonu, doğru görüntü sınıflandırması ve diğer bilgisayarla görme görevleri için gerekli olan yüksek derecede doğrusal olmayanlığı korurken hesaplama açısından verimli olacak şekilde tasarlanmıştır. MOAT (Yang vd. 2022) mobil konvolüsyonları ve dikkat mekanizmalarını tek bir blokta birleştirmektedir. Ayrı mobil konvolüsyon ve Transformer bloklarını yığan önceki yaklaşımların aksine MOAT, bunları çok katmanlı algılayıcının mobil bir konvolüsyon bloğu ile değiştirildiği tek bir blokta birleştirmektedir. MOAT bloğu ağ temsil kapasitesini artırmakta ve daha iyi örneklenmiş özellikler üretmektedir.

2.4 Darboğazlı Transformerlar

Darboğazlı Transformer mimarileri, bilgisayarla görmenin çeşitli uygulamalarında etkili ve doğru çözümler sunarak dikkate değer bir ilgi kazanmıştır. Bu mimariler, Transformerların güçlü yönlerini ve darboğaz yapılarını birleştirerek uzun menzilli bağımlılıkların etkili bir şekilde modellenmesini sağlarken hesaplama maliyetlerini en aza indirmektedirler. Bu alandaki dikkate değer katkılardan biri, Srinivas ve arkadaşları tarafından önerilen darboğazlı Transformer (Bottleneck Transformer (BoT)) mimarisidir (Srinivas vd. 2021). BoT, azaltılmış boyutlu bir alanda öz-dikkat mekanizmalarını içeren yeni bir darboğaz bloğu sunmuştur. Bu yaklaşım, etkili özellik temsillerin elde edilmesini mümkün kılmış ve bağlamsal bilginin daha iyi yakalanmasını sağlayarak görü sınıflandırması ve nesne tespiti gibi bilgisayarla görme görevlerinde yüksek performansların elde edilmesini sağlamıştır.

Diğer bir dikkate değer mimari, Zheng vd. (2021) tarafından geliştirilen Vision Transformer Plus (ViT+)'tır. ViT+, darboğaz yapısını geliştirerek hiyerarşik bir dikkat mekanizması getirmiş ve çok katmanlı temsillerin yakalanmasını ve ağ içinde bilgi akışının iyileştirilmesini sağlamıştır. Deneysel değerlendirmeler, ViT+'ın çeşitli bilgisayarla görme ölçütlerinde en iyi sonuçları elde ettiğini göstermiştir. Bu bağlamda, Li vd. (2022), ViT'ların verimliliğini artırmak için darboğaz dikkat mekanizmasını içeren Darboğaz-Transformer mimarisini önermiştir. Bilgileri seçici olarak dikkate

olarak ve darboğaz yapılarını kullanarak, Darboğaz-Transformer rekabetçi performans sağlamakta ve hesaplama gereksinimlerini azaltmakta, böylece gerçek dünya bilgisayarlı görü uygulamaları için uygun hale gelmektedir. Darboğazlı Transformer mimarileri, bilgisayarla görme görevlerinde hesaplama verimliliği ve doğruluk arasında bir denge sağlayarak etkinliklerini kanıtlamıştır. Bu mimariler, öz-dikkat mekanizmalarının ve darboğaz yapılarının gücünden yararlanarak bilgisayarla görme alanında ilerlemeler kaydetmiştir.

Genel olarak literatürde histopatolojik görüntülerde çekirdek segmentasyonu için bir çok çalışma yapılmıştır. Bu çalışmaların başında gelen geleneksel yöntemler genellikle el yapımı özelliklere dayanmaktadır. Bu da bu yöntemlerin karmaşık görüntülerde ve büyük ölçekli veri setlerinde uygulanmalarını kısıtlamaktadır. Derin öğrenme yöntemleri ise karmaşık ilişkilerin modelleme yetenekleri ve iyi genelleme yapabilme özelliklerinden dolayı güncel literatürde çekirdek segmentasyonu gibi birçok tıbbi görüntü analizi uygulamalarında daha çok tercih edilmektedir. Bu yöntemlerin büyük kısmı CNN tabanlı mimarileri kullanmaktadır. Bu mimariler arasında, U-Net mimarisi en çok tercih edilen ve öne çıkan mimaridir. Ancak U-Net mimarisi, çoğu CNN tabanlı mimariler gibi aşırı uyma, sınırlı alıcı alan ve görüntü kalitesine duyarlılık gibi sorunlarla karşı karşıyadır. Literatürde çok sayıda çalışma, bu sorunlarla birlikte çekirdek segmentasyonuna has en büyük sorunlardan olan çekirdeklerin örtüşme ve çok değişkenli şekillerde olabilme sorunlarını ele almıştır. Bu çalışmalarda önerilen çözümlerin büyük kısmı, alıcı alanı genişletmek için ASPP gibi ekstra modüllerin eklenmesi, örtüşen çekirdeklerin doğru tespiti için birden fazla kod çözücülerin kullanılmasından oluşmaktadır. Bu çalışmaların küçük bir kısmı ise CNN mimarilerine Transformer mimarilerini entegre ederek uzun bağımlılıkların modellenmesini sağlamaktadır. Bazı çalışmalar ise mimarilerinin aşırı uyma sorunu hafifletmek ve genel performansını artırmak için farklı veri artırma yöntemleri ve özel kayıp fonksiyonlarını kullanmışlardır. Bu yöntemler çekirdek segmentasyonunda başarılı sonuçların elde edilmesini sağlamış olsa da hala eksik yönleri ve ele almadığı sorunlar mevcuttur. Yeterli alıcı alanın sağlanması için eklenen ekstra bloklar ya da ekstra kod çözücü yolları kendi hesaplama maliyetleri getirmekle birlikte bazen efektif olmamaktadır. Transformer mimarileri uzun bağımlılıkları modellenmesinde etkili olsa da bu blokların

bağımsız olarak kullanması özelliklerin konumsal bilgilerin kaybedilmesine yol açabilmektedir. Ayrıca literatürde girdi görüntülerde olası gürültülere karşı mimari seviyesinde herhangi bir çözüm önerilmemektedir.

Bu tez çalışmasında, literatür taraması sonucunda tespit edilen güncel çalışmaların eksikleri ışığında daha doğru ve etkili bir şekilde çekirdek segmentasyonu gerçekleştiren CompSegNet adı verilen derin öğrenmeye dayalı yeni bir mimari önerilmiştir. Bu mimari, U-Net mimarisini temel almaktadır ve temel kodlayıcı ve kod çözücü blokları olarak yüksek hesaplama verimliliği, düşük model karmaşıklığı ve yüksek doğruluk sağlama yetenekleriyle bilinen mobil konvolüsyon bloklarını kullanmaktadır. CompSegNet, U-Net mimarisi başta olmak üzere CNN tabanlı mimarilerin büyük kısmının karşılaştığı sınırlı alıcı alan sorununu etkili bir şekilde ele almak için kullanılan mobil konvolüsyon temel blokları için Büyüt-Filtrele-Küçült adı verilen yeni bir yeterli alıcı alan genişletme yöntemi önermiştir. Bu bloklara ayrıca iyileştirilmiş bir küresel bağlam bloğu entegre edilerek az bir ekstra parametre sayısı ile mimarinin genel küresel bağlam modellemesi yeteneği artırılmıştır. Hem uzun bağımlılıkların modellenmesi hem de özelliklerin konumunu etkili bir şekilde korunmasını sağlamak için mimarinin darboğazında kullanılmak üzere Sanglass ve Transformer bloklarını uygun ve verimli bir şekilde entegre eden yeni bir darboğaz bloğu önerilmiştir. Mimari, girdi görüntülerinde olası gürültülerin atlama bağlantıları yoluyla kod çözücü yoluna gönderilerek mimarilerinin performansını etkileme sorununu hafifletmek için kodlayıcı yolunun ilk bloğu olarak kullanılmak üzere gürültüye duyarlı kök (GDK) bloğu önermiştir. Son bir katkı olarak CompSegNet mimarisinin genel performansını artırmak için çekirdeklerin hem pikselleri hem de alanlarını dikkate alan ve veri setindeki sınıf dengesizliği sorununu etkili bir şekilde ele alan BCE ve Dice kayıp fonksiyonlarının kombine eden bir kayıp fonksiyonu önerilmiştir.

Bu bölümde, geleneksel ve derin öğrenme tabanlı çekirdek segmentasyonu yöntemlerine dair yapılan literatür çalışmaları özetlenmiştir. Ardından, mobil ağlar ve darboğaz Transformer mimarilerine genel bir bakış sunulmuştur. Son olarak, bu bilgiler ışığında, önerilen CompSegNet mimarisinin ele aldığı sorunlar ve bu sorunlara yönelik

öneriler özetlenmiştir. Bir sonraki bölümde, CompSegNet mimarisinin geliştirilmesine ilişkin açıklamalar sunulmaktadır.

3. COMPSEGNET MİMARİSİNİN GELİŞTİRİLMESİ

Bu bölümde, öncelikle H&E boyalı histopatolojik görüntülerde çekirdek segmentasyonu için önerilen CompSegNet mimarisi açıklanmaktadır. Ardından, CompSegNet mimarisinin geliştirilmesinde temel alınan bloklar, bu blokların iyileştirilmesi ve CompSegNet mimarisine dahil edilmesi yöntemleri hakkında açıklamalar verilmektedir. Daha sonra, CompSegNet mimarisi için önerilen kayıp fonksiyonu ve mimarinin değerlendirilmesi için kullanılması önerilen değerlendirme metrikleri hakkında detaylı bilgi sunulmaktadır. Son olarak, bu bölümün genel bir değerlendirilmesi yapılmaktadır.


3.1 CompSegNet Mimarisi

Bu alt bölüm, H&E boyalı histopatolojik görüntülerde çekirdeklerin anlamsal (semantic) segmentasyonu için önerilen CompSegNet mimarisini açıklamaktadır.

CompSegNet mimarisi, temel olarak dört ana bölümden oluşmaktadır: kodlayıcı, darboğaz, kod çözücü ve segmentasyon bloğu (şekil 3.1). Mimaride, kodlayıcı girdi görüntülerini düşük boyutlu sıkıştırılmış özellik haritalarına kodlamaktan sorumludur. Darboğaz, bu özellik haritalarında gereksiz bilgileri baskılayarak kod çözücü için gerekli olan bilgileri öne çıkarmak ve sonuç özellik haritalarını kod çözücüye iletmekle görevlidir. Kod çözücünün görevi, darboğazdan alınan sıkıştırılmış özellik haritalarını çözerek girdi görüntünün uzamsal boyutunda yeni özellik haritalarını oluşturmaktır. Segmentasyon bloğu ise kod çözücünün sonuç özellik haritalarından segmentasyon maskelerini oluşturma görevini üstlenmektedir.

Kodlayıcı, bir $I \in \mathbb{R}^{H \times W \times 3}$ görüntüsünü girdi olarak alıp bir $f_1 \in \mathbb{R}^{H \times W \times 64}$ özellik haritasını üreten bir kök bloğu ile başlamaktadır; burada H , W , 3 ve 64 sırasıyla I görüntüsünün yüksekliği, genişliği, RGB kanal sayısı ve f_1 'in genişletilmiş kanal sayısını göstermektedir. Bu bloğu, uzamsal alt örnekleme (downsampling) ve kanal

geniřletme oranları sırasıyla $s \in \{\frac{1}{2}, \frac{1}{4}, \frac{1}{8}\}$ ve $c \in \{2, 4, 8\}$ olarak ayarlanan üç özdeş kodlayıcı bloęu takip etmektedir. Bu yapılandırmalarla, her kodlayıcı bloęunda girdi özellięinin uzamsal boyutu yarıya indirilmekte ve kanal sayısı iki katına çıkarılmaktadır.



Şekil 3.1 Önerilen CompSegNet'in genel mimarisi

Kodlayıcının son bloęundan sonra darboęaz olarak önerilen artık darboęazlı Transformer (ADT) bloęu uygulanmaktadır. Bu blok, girdi özellik haritasının uzamsal boyutunu yarıya indirerek ve kanal sayısını iki katına çıkararak $f_5 \in \mathbb{R}^{\frac{H}{16} \times \frac{W}{16} \times (16C)}$

özellik haritasını oluşturmaktadır; burada H , W ve C , kök blok çıktı özellik haritasının uzamsal ve kanal boyutlarıyla aynıdır. Kod çözücü, bu düşük boyutlu sıkıştırılmış özellik haritalarını sırayla dört kod çözme adımından (stride) geçirerek tam çözünürlüklü özellik haritalarını oluşturmaktadır. Her kod çözme adımında, alt seviyeden gelen özellik haritaları iki katı üst örnekleme (upsampling) atlama bağlantıları yoluyla kodlayıcıdan gelen ilgili özellik haritalarıyla birleştirilmektedir. Bu özellikler, daha sonra ilgili kodlama seviyesiyle aynı uzamsal ve kanal boyutlarına sahip özellik haritalarını üreten bir kod çözücü bloęuna iletilmektedir.

Segmentasyon bloęu, doğrusal bir dönüşümle kod çözücüden gelen özellik haritalarını, $f_9 \in \mathbb{R}^{H \times W \times 64}$, istenen segmentasyon maskesine, $f_{10} \in \mathbb{R}^{H \times W \times N}$, dönüştürmektedir; burada H ve W sırasıyla girdi görüntüsünün yükseklięi ve genişlięi, N ise hedef sınıf sayısını göstermektedir.

İkili (binary) segmentasyon görevlerinde, N 'nin değeri 1 olarak belirlenmektedir. CompSegNet mimarisinin ayrıntılı yapısı çizelge 3.1'de verilmektedir. Çizelge 3.1'de birim seviyeleri, kodlama, darboğaz ve kod çözme adımlarına karşılık gelmektedir. İşlemciler bu seviyelerde uygulanan işlemleri veya blokları temsil etmektedir. Adım ve filtreler, sırasıyla her işlemdeki son konvolüsyon katmanında uygulanan adım boyutu ve filtre sayısını göstermektedir. Çıktı boyutu, her işlemden sonra elde edilen çıktı özellik haritasının veya oluşturulan maskenin boyutunu belirtmektedir. BÜ-Birleştir ise, bilineer yöntemle üst örnekleme ve birleştirme işlemlerini ifade etmektedir.

Çizelge 3.1 CompSegNet'in ayrıntılı yapısı

	Birim seviyesi	İşlemci	Adım	Filtre	Çıktı boyutu
Girdi					$256 \times 256 \times 3$
Kodlayıcı	Seviye 1	GDK	1	64	$256 \times 256 \times 64$
	Seviye 2	CSeg	1	128	$256 \times 256 \times 128$
		ECSeg	2	128	$128 \times 128 \times 128$
	Seviye 3	CSeg	1	256	$128 \times 128 \times 256$
		ECSeg	2	256	$64 \times 64 \times 256$
	Seviye 4	CSeg	1	512	$64 \times 64 \times 512$
		ECSeg	2	512	$32 \times 32 \times 512$
Darboğaz	Seviye 5	ADT	2	1024	$16 \times 16 \times 1024$
Kod çözücü	Seviye 6	BÜ-Birleştir	2	—	$32 \times 32 \times 1536$
		ECSeg	1	512	$32 \times 32 \times 512$
	Seviye 7	BÜ-Birleştir	2	—	$64 \times 64 \times 768$
		ECSeg	1	256	$64 \times 64 \times 256$
	Seviye 8	BÜ-Birleştir	2	—	$128 \times 128 \times 384$
		ECSeg	1	128	$128 \times 128 \times 128$
	Seviye 9	BÜ-Birleştir	2	—	$256 \times 256 \times 192$
		ECSeg	1	64	$256 \times 256 \times 64$
Segmentasyon	Seviye 10	1×1 Conv2d	1	1	$256 \times 256 \times 1$

Çizelge 3.1’de görüldüğü gibi, CompSegNet mimarisi girdi olarak $I \in \mathbb{R}^{256 \times 256 \times 3}$ boyutunda bir görüntü alırken çıktı olarak $M \in \mathbb{R}^{256 \times 256 \times 1}$ boyutunda bir segmentasyon sonuç maskesini oluşturmaktadır. Mimari, toplamda 10 seviyeden oluşmaktadır. Kodlayıcının ilk seviyesinde önerilen GDK bloğu kullanılmakta, diğer seviyelerinde ise sırasıyla önerilen CSeg ve ESeg blokları uygulanmaktadır. Kod çözücü seviyelerinde üst örnekleme ve birleştirme işlemlerinden sonra ESeg bloğu, segmentasyon seviyesinde ise 1×1 boyutlu filtre kullanan tek bir konvolüsyon katmanı uygulanmaktadır.


3.2 CompSegNet Mimarisinde Kullanılan Temel Bloklar

Bu bölümde, CompSegNet mimarisinin farklı seviyelerinde kullanılmak üzere önerilen temel bloklar hakkında ayrıntılı bilgiler sunulmaktadır. Bu bloklar arasında, güncel literatürde yer alanlar hem açıklanmakta hem de bu blokların eksiklikleri ve bu eksiklikleri gidermek için yapılan iyileştirmelere dair açıklamalar verilmektedir.

3.2.1 Gürültüye duyarlı kök bloğu

Derin öğrenme mimarilerinde, ilk özellik çıkarma blokları girdi görüntülerindeki olası gürültülerden etkilenecek gürültülü özellikleri oluşturabilmektedir. U-Net gibi atlama bağlantılarını kullanan mimarilerde ise, mimarinin üst seviyelerinde oluşan bu gürültülü özellikler, atlama bağlantıları aracılığıyla kod çözücüye yayılıp mimarinin genel segmentasyon performansını etkileyebilmektedir. Gürültüye duyarlı kök (GDK) bloğu, CompSegNet mimarisinde bu sorunu gidermek amacıyla özel olarak tasarlanmıştır. Bu bağlamda GDK bloğu, gürültülü özelliklerin olumsuz etkisini azaltmak için yüksek seviyelerde kod çözücüye yayılan özelliklerin kalitesini artırarak ilk atlama bağlantısı yoluyla gürültülerin yayılmalarını önlemektedir. GDK bloğunun tasarım detayları şu şekildedir: İlk olarak girdi görüntüsü 3×3 konvolüsyon ile filtrelenmekte ve RGB kanalları 64 kanal sayısına çıkartılmaktadır. Daha sonra, her bir kanalı ayrı ayrı işleyen hafif bir 7×7 derinlemesine konvolüsyon uygulanarak pikseller arasındaki yerel

uzamsal etkileşimler yakalanmaktadır. Ardından, özellik kanal sayısını iki katına genişleten bir 1×1 konvolüsyon katmanı ve bunları geri sıkıştıran ikinci bir 1×1 konvolüsyon katmanı uygulanmaktadır. Son olarak, bir artık bağlantı kullanılarak 3×3 konvolüsyon katmanının çıktı özellik haritaları ile son 1×1 konvolüsyon katmanının çıktı özellik haritaları birleştirilmektedir. GDK bloğundaki ilk konvolüsyon katmanı, toplu normalleştirme (batch normalization) ve ReLU doğrusal olmayanı (non-linearity, activation function) uygulamaktadır. İkinci konvolüsyon katmanında katman normalleştirme (layer normalization) kullanılırken, üçüncü konvolüsyon katmanında sadece GeLU doğrusal olmayanı kullanılmaktadır. Son konvolüsyon katmanı ise çıkartılan özelliklerde doğrusal bilgilerin kaybını engellemek ve potansiyel bozulmaları önlemek için herhangi bir doğrusal olmayanı uygulamaktadır. GDK bloğunun ayrıntılı yapısı şekil 3.2'de gösterilmektedir.



Şekil 3.2 GDK bloğunun ayrıntılı yapısı

Şekil 3.2'de, "Conv" konvolüsyon işlemine, "BatchNorm" toplu normalleştirme işlemine, "DepthwiseConv" derinlemesine konvolüsyon işlemine, "LayerNorm" ise katman normalleştirme işlemine karşılık gelmektedir.

3.2.2 CompSeg ve genişletilmiş CompSeg blokları

Bu alt bölümde, MBConv bloğunun açıklaması yapılmakta ve ardından bu bloğun

eksikliklerini gidermek için geliştirilen CompSeg (CSeg) ve genişletilmiş CompSeg (ECSeg) bloklarının ayrıntılı bilgileri sunulmaktadır.

MBConv bloğu. İlk olarak Sandler vd. (2018) tarafından tanıtılan Mobil Konvolüsyon (MBConv) Bloğu, özellikle mobil tasarımlar için tasarlanmış hafif bir yapı taşıdır. MBConv bloğu, ResNet (Tai vd. 2017) mimarilerindeki klasik darboğaz yapısının aksine verimlilik nedenleriyle ters çevrilmiş bir artık yapısı kullanmaktadır. Daha spesifik olarak MBConv bloğu önce 1×1 konvolüsyon kullanarak girdi özellik kanallarını 6 kat kadar genişletir, ardından her kanaldaki uzamsal bağlamı modellemek için 3×3 derinlemesine konvolüsyon uygular. Son olarak elde edilen özellikleri girdi kanalı boyutuna geri yansıtmak için 1×1 konvolüsyon uygulamaktadır. Derinlemesine konvolüsyonun adımı 1 olarak ayarlandığında artık bir bağlantı uygulanmaktadır. Derinlemesine konvolüsyonda her kanal eşit önemle işlenmektedir. Ancak, bazı çalışmalarda (Howard vd. 2018; Tan vd. 2019) olduğu gibi, SE gibi küresel bağlam modülleri kullanılarak kanal bazında öneme göre özellik haritalarının yeniden ağırlıklandırılması sağlanabilmektedir (Hu vd. 2018).

Girdi tensörü olarak $x \in \mathbb{R}^{H \times W \times C}$ verildiğinde, burada H , W ve C sırasıyla x tensörünün yüksekliği, genişliği ve kanal sayısını göstermektedir, MBConv bloğu şu şekilde formüle edilebilmektedir:

$$MBConv(x) = x + (P \circ F \circ E)(x), \quad (\text{Denklem 1})$$


$$E(x) = ReLU6(BN(Conv(x))), \quad (\text{Denklem 2})$$

$$F(x) = ReLU6(BN(DepthConv(x))), \quad (\text{Denklem 3})$$

$$P(x) = BN(Conv(x)), \quad (\text{Denklem 4})$$

Burada, BN ve $ReLU6$ sırasıyla toplu normalleştirme (Ioffe vd. 2015) ve maksimum değer sınırlaması 6 olan doğrultulmuş doğrusal birim (Nair vd. 2010) anlamına gelmektedir (Sandler vd. 2018). MBConv üç ana işlem uygulamaktadır: genişletme (E), filtreleme (F) ve projeksiyon (P), bunlar sırasıyla 1×1 konvolüsyon, 3×3 derinlemesine konvolüsyon ve 1×1 konvolüsyon işlemlerine karşılık gelmektedir.

Şekil 3.3, MBConv bloğunun ayrıntılı yapısını göstermektedir. Bu şekilde, s_1 ve s_2 sırasıyla ilk konvolüsyon ve derinlemesine konvolüsyon katmanlarında uygulanan adım sayısını belirtmektedir. Diğer ifadeler ise, şekil 3.2’deki ifadelerle aynı işlemleri temsil etmektedir.



Şekil 3.3 MBConv bloğunun ayrıntılı yapısı

Burada, gözlemlenebildiği gibi temel MBConv bloğu yalnızca kanal bazında genişletme gerçekleştirmektedir. Daha net ifade etmek gerekirse MBConv bloğunda uzamsal olarak herhangi bir genişletme yapılmamaktadır. Ancak uzamsal genişletme etkili bir şekilde ele alındığında, mimarinin verimliliği artırılabilir. Başka bir husus ise, MBConv bloğunun bütün özellik harita kanallarını aynı önemle işlemesidir. CompSegNet mimarisinin geliştirilmesinde MBConv bloğundaki bu eksiklikleri etkili bir şekilde ele alarak CSeg ve ESeg temel blokları önerilmiştir. CSeg ve ESeg blokları, CompSegNet mimarisinde kullanıldığında, sınır alıcı alan sorununu etkin bir şekilde çözmekte ve mimarinin genel performansını artırmaktadır. Ayrıca, bu bloklar

mimarinin küresel bağlam modelleme yeteneğini artırmaktadır. Aşağıda, CSeg ve ECSeg bloklarının motivasyonlarıyla birlikte açıklamaları verilmektedir.

CSeg bloğu. Görme duyusunun sabit olduğu ve uzamsal ayrıntıları yakalamak için yakınlaştırmayı gerekli kılan insan görsel sisteminin aksine, CNN'ler, görüntülerden bilgilendirici özellikleri yakalamak için ayarlanabilir boyutlu filtreleri kullanırlar. Ancak alıcı alan boyutu, CNN mimarilerinin hem başarısını hem de gecikmesini doğrudan etkileyen bir faktördür. MBConv bloğu, mobil tasarımlar için optimize edildiğinden, standart olarak 3×3 boyutlu filtreleri kullanırlar. Ancak bu sayının artırılması, mimarilerinin bellek kullanımını ve çıkarım gecikmesini artırabilmektedir. Bu bağlamda MBConv bloğunda geniş bir alıcı alan sağlamak için yeni bir yakınlaştırma yöntemi önerilmektedir. Önerilen yöntem, bloğun bellek ve hesaplama maliyetini optimize ederken aynı zamanda girdi görüntüsünün veya özellik haritasının geniş bir alanını kapsayarak bloğun uzamsal bağlam modelleme yeteneğini artırmaktadır. Önerilen yöntem şu şekilde çalışmaktadır: İlk olarak MBConv bloğundaki ilk 1×1 konvolüsyon katmanında geniş bir adım boyutu kullanılarak bloğun alıcı alanı genişletilmektedir. Ardından, derinlemesine konvolüsyon katmanında geniş boyutlu bir filtre uygulanarak hem özellik haritaları filtrelenmekte hem de alıcı alanı daha da genişletilmektedir. Son olarak derinlemesine konvolüsyon işleminden sonra büyük adımların neden olduğu alt örnekleme telafi edilmesi amacıyla bilineer üst örnekleme uygulanmaktadır.

Bu yöntem genel olarak "Büyüt-Filtrele-Küçült" (BFK) olarak adlandırılmaktadır. Burada "Büyüt" (zoom in), alıcı alanını genişletmek için büyük adımlı konvolüsyon kullanmayı ifade ederken; "Filtrele", büyük filtre boyutlu derinlemesine konvolüsyon kullanarak hem özellik haritalarının filtrelenmesini hem de alıcı alanının daha da genişletilmesini sağlamayı ifade etmektedir. "Küçült" (rescale veya zoom out) ise büyük adımın neden olduğu alt örneklemeyi telafi etmek amacıyla bilineer üst örnekleme kullanarak uzamsal boyutun yeniden ölçeklendirilmesini ifade etmektedir. Bu yakınlaştırma yöntemi MBConv bloğuna uygulandığında, elde edilen blok "CompSeg" (CSeg) olarak adlandırılmıştır. Giriş tensörü olarak $x \in \mathbb{R}^{H \times W \times C}$ verildiğinde, CSeg bloğu şu şekilde formüle edilebilmektedir:

$$CSeg(x) = ReLU(x + (P \circ U \circ F \circ E)(x)), \quad (\text{Denklem 17})$$


$$E(x) = ReLU(BN(Conv_{s_2}(x))), \quad (\text{Denklem 18})$$

$$F(x) = ReLU(BN(DepthConv(x))), \quad (\text{Denklem 19})$$

$$U(x) = UpSample_{s_2}(x), \quad (\text{Denklem 20})$$

$$P(x) = BN(Conv_{s_1}(x)), \quad (\text{Denklem 21})$$

Burada U , 2×2 bilineer üst örnekleme fonksiyonunu, $Conv_{s_1}$ ve $Conv_{s_2}$ ise sırasıyla $s = 1$ ve $s = 2$ adım sayılarını kullanan konvolüsyon katmanlarını ifade etmektedir. Şekil 3.4, CSeg bloğunun genel yapısını göstermektedir. Burada, s_1 , s_2 , ve s_3 ilgili konvolüsyon katmanlarında uygulanan adım sayılarını belirtmektedir. BUpsample, bilineer üst örnekleme işlemi ifade etmektedir. Şekilden fark edildiği gibi CSeg, MBConv bloğundan farklı olarak $ReLU6$ yerine $ReLU$ kullanmaktadır. Ayrıca girdi özellik haritalarını çıktı özellik haritalarıyla birleştirmek için 1×1 filtre boyutlu bir konvolüsyon katmanı kullanmaktadır. Bu katmanın adım sayısı, derinlemesine konvolüsyon katmanının adım sayısı ile aynı olmaktadır. CSeg bloğu, BFK yönteminin ayarları olarak ilk konvolüsyon katmanında 2 adım sayısını kullanırken, derinlemesine konvolüsyon katmanında 7×7 boyutlu bir filtre uygulamaktadır. Ardından özellik haritasının uzamsal boyutunu yeniden ölçeklendirmek için 2×2 bir bilineer üst örnekleme işlemi uygulamaktadır. Bu ayarlarla MBConv bloğundaki alıcı alan neredeyse 8 kat artmaktadır. İlk ayar neredeyse 2 kat, ikinci ayar ise neredeyse 4 kat artmaktadır. Ayrıca bu ayarlar CompSegNet mimarisindeki başarıyı artırırken çıkarım süresinde yaklaşık %30'luk bir azalmaya neden olmaktadır. CSeg bloğunun parametre ve girdi/çıktı boyut detayları çizelge 3.2'de verilmektedir.



Şekil 3.4 CSeg bloğunun ayrıntılı yapısı

Çizelge 3.2 CSeg bloğunun parametre ve girdi / çıktı detayları

Girdi	İşlemci	Çıktı
$h \times w \times k$	1×1 conv2d, $s = s_1$, BN, ReLU	$\frac{h}{s_1} \times \frac{w}{s_1} \times (tk)$
$\frac{h}{s_1} \times \frac{w}{s_1} \times (tk)$	7×7 dwise, $s = s_2$, BN, ReLU	$\frac{h}{s_1 \times s_2} \times \frac{w}{s_1 \times s_2} \times (tk)$
$\frac{h}{s_1 \times s_2} \times \frac{w}{s_1 \times s_2} \times (tk)$	$s_1 \times s_1$ bilinear üst örnekleme	$\frac{h}{s_2} \times \frac{w}{s_2} \times (tk)$
$\frac{h}{s_2} \times \frac{w}{s_2} \times (tk)$	1×1 conv2d, ReLU	$\frac{h}{s_2} \times \frac{w}{s_2} \times k'$

Bu çizelgede, CSeg bloğu, k filtre sayısına sahip bir özellik haritasını k' filtre sayısına sahip bir özellik haritasına dönüştürmektedir. Burada s_1 ve s_2 ilgili katmanlarda


uygulanan adım sayılarını temsil etmektedir. h , w ve k , sırasıyla girdinin yüksekliği, genişliği ve kanal sayısını gösterirken t , girdi kanal sayısının artış oranını temsil etmektedir.

ECSeg bloğu. MBConv bloğunda olduğu gibi, CSeg bloğu girdi özellik haritasında bütün kanalları aynı önemle işlemektedir. MBConv bloğunda kanalların önem derecelerine göre işlenerek öğrenilen özelliklerin otomatik olarak yeniden ağırlıklandırılması (self-reweighting) için Howard vd. (2018) ve Tan vd. (2019) çalışmalarında SE modülü kullanılmıştır. CSeg bloğunda, bu sorunu ele almak için GC bloğu (Cao vd. 2019) geliştirilmiş ve CSeg bloğuna entegre edilmiştir. Sonuç bloğu, genişletilmiş CompSeg (ECSeg) bloğu olarak adlandırılmıştır.

GC bloğu, girdi görüntüsündeki uzamsal bağımlılıkların etkili bir şekilde modellenmesi için basitleştirilmiş yerel olmayan (simplified nonlocal (SNL)) bloğunun uzun menzilli bağımlılıkları (long-range dependency) etkili bir şekilde modelleme yeteneği ve SE bloğunun hafif hesaplama özelliğinden faydalanarak tasarlanmış bir bloktur. GC bloğunun çalışma prensibi şu şekildedir: İlk olarak, girdi özellik haritası küresel bağlamı yakalamak için bir 1×1 konvolüsyon ile filtrelenir. Ardından, elde edilen çıktı üzerinde bir softmax işlemi uygulanarak bir bağlam maskesi oluşturulur. Daha sonra, bu maske, girdi özellik haritasıyla çarpılarak küresel bağlam özellikleri elde edilmektedir. İkinci adımda, yakalanan küresel bağlam özelliklerini zenginleştirmek için bir dönüşüm işlemi gerçekleştirilmektedir. Bu dönüşüm işleminde, özellikler öncelikle daha az filtre sayısını kullanan bir 1×1 konvolüsyon ile filtrelenir. Daha sonra, girdi filtre sayısına çıkarmak için yeni bir 1×1 konvolüsyon uygulanarak kanalların önem derecelerini belirleyen yeni bir özellik haritası oluşturulur. Son olarak bu yeni özellik haritası girdi özellik haritasına eklenerek girdi haritasında bütün kanallar önem derecelerine göre yeniden ağırlıklandırılmaktadır. Ayrıca GC bloğu, dönüşüm bölümünde optimizasyonu kolaylaştırmak amacıyla katman normalleştirmeyi ve ardından ReLU doğrusal olmayan fonksiyonunu uygulamaktadır.

ECSeg bloğunun tasarımında, ilk olarak CSeg bloğuna temel GC bloğu entegre edilerek bloğun etkili bir şekilde küresel bağlam modellemesi sağlanmıştır. Bu iyileştirme, az ek

parametre ile CompSegNet mimarisinin başarısını AJI skorunda %1.1 kadar artırmıştır. Ardından GC bloğunun bağlam modelleme bölümünde, bağlam maskesini doğrudan girdi özellik haritasına uygulamak yerine öncelikle 1×1 konvolüsyon işlemiyle girdi özellik haritasının zenginleştirilmesi sağlanmış ve ardından bağlam maskesi uygulanmıştır. Bu iyileştirilmiş GC bloğu, İyileştirilmiş GC (IGC) bloğu olarak adlandırılmıştır. IGC bloğunun CSeg ile entegre edilmesi, CompSegNet mimarisine ekstra %0.80 AJI skorunda bir başarı sağlamıştır. Bu sonuç bloğu, genişletilmiş CompSeg (ECSeg) bloğu olarak adlandırılmıştır. Şekil 3.5, IGC ve ECSeg bloklarını göstermektedir.



Şekil 3.5 IGC (solda) ve ECSeg (sağda) bloklarının yapısı

IGC bloğunda, A_1 , A_2 , A_3 , ve A_4 ilgili konvolüsyon katmanlarında oluşturulan ağırlıkları gösterirken H , W ve C sırasıyla ilgili katmanın çıktı özellik haritasının yüksekliği, genişliği ve kanal sayısını göstermektedir. Burada, A_2 özel olarak eklenen ağırlıktır. Dönüşüm bölümünde, r (ratio) ise, ilgili katmanda girdi özellik haritasının kanallarının bölünme oranını temsil etmektedir. CSeg bloğu, IGC bloğu ile entegre edilirken son katmanında GeLU aktivasyon fonksiyonu kullanılarak bloğun optimizasyon ve yakınsama performansı iyileştirilmiştir. Bu blok, şekil 3.5'te $CSeg_G$ olarak gösterilmektedir.

3.2.3 Artık Darboğazlı Transformer bloğu

Bu alt bölümde, öncelikle Artık Darboğazlı Transformer (ADT) bloğunun tasarımında temel alınan Sandglass ve Transformer blokları hakkında detaylı bilgi verilmektedir. Daha sonra, bu blokların entegrasyonu ile ADT bloğunun tasarımı ve işlevi detaylı bir şekilde açıklanmaktadır.

Sandglass Bloğu. Sandglass bloğu, verimli sinir ağları tasarımında klasik darboğaz yapısının, tersine çevrilmiş artık (inverted residual) yapısına göre daha etkili olduğunu göstermek amacıyla tasarlanmış ve MobileNeXt (Zhou vd. 2020) mimarisinde temel yapı taşı olarak kullanılmıştır. Bu blok, ters çevrilmiş artık blokların aksine, dar katmanlar yerine yüksek boyutlu özellik haritaları arasında kimlik eşlemesi (identity mapping) yapmaktadır. Daha spesifik olarak Sandglass bloğu öncelikle pikseller arasındaki yerel uzamsal etkileşimleri öğrenmek için 3×3 derinlemesine konvolüsyon uygular. Ardından sırasıyla özellik kanalı genişletme ve azaltma için iki adet 1×1 konvolüsyon işlemini gerçekleştirmektedir. Son olarak tekrar 3×3 derinlemesine konvolüsyon uygulanarak uzamsal bağlam modellemesi yapılmaktadır. Bu tasarım, ters çevrilmiş artık bloğunda karşılaşılan bilgi kaybı ve gradyan karışıklığı sorunlarını hafifletmektedir.

Giriş tensörü olarak $x \in \mathbb{R}^{H \times W \times C}$ verildiğinde, Sandglass bloğu şu şekilde formüle edilebilmektedir:

$$\text{Sandglass}(x) = x + (F_2 \circ P \circ E \circ F_1)(x), \quad (\text{Denklem 9})$$


$$F_1(x) = \text{ReLU6}(\text{BN}(\text{DepthConv}(x))), \quad (\text{Denklem 10})$$

$$E(x) = \text{BN}(\text{Conv}(x)), \quad (\text{Denklem 11})$$

$$P(x) = \text{ReLU6}(\text{BN}(\text{Conv}(x))), \quad (\text{Denklem 12})$$

$$F_2(x) = \text{BN}(\text{DepthConv}(x)), \quad (\text{Denklem 13})$$

Burada, F_1 ve F_2 3×3 derinlemesine konvolüsyon katmanlarını belirtirken, E ve P 1×1 konvolüsyon kullanan genişletme ve projeksiyon katmanlarını temsil etmektedir. Sandglass bloğu, her katmanda BN kullanırken, sadece birinci derinlemesine konvolüsyon ve ikinci konvolüsyon katmanlarında $ReLU6$ aktivasyon fonksiyonunu kullanmaktadır. Şekil 3.6, Sandglass bloğunun genel yapısını göstermektedir. Basitlik amacıyla şekilde normalleştirme ve aktivasyon fonksiyonları gösterilmemiştir.



Şekil 3.6 Sandglass bloğunun genel yapısı

Sandglass bloğu, varsayılan olarak ilk derinlemesine konvolüsyonda adım sayısı 1 kullanırken, duruma bağlı olarak son derinlemesine konvolüsyonda farklı değerler kullanabilmektedir. Şekil 3.6'da adım sayıları s ile gösterilmektedir. İkinci konvolüsyonda girdi özellik haritasının kanal bölme oranı ise 4 olarak varsayılmaktadır.

Transformer Bloğu. Transformer (Vaswani vd. 2017) blokları, iç dikkat (intra-attention) mekanizması olarak da adlandırılan bir öz dikkat (self-attention) mekanizması kullanarak dizilerden küresel bağlamsal bilgileri etkili bir şekilde yakalayan verimli yapı taşlarıdır. Transformer blokları iki ana katmandan oluşmaktadır.

Bunlar bir çok kafalı öz dikkat (multi-head self-attention (MHSA)) katmanı ve bir ileri beslemeli ağ (feed-forward network (FFN)) katmanıdır. Her iki katmanı da bir katman normalleştirme işlemi ve bir artık bağlantı takip etmektedir. MHSA, kafalar olarak bilinen paralel öz dikkat işlemlerinin bir koleksiyonundan oluşmaktadır. Bu kafalar, girdi özellik tensöründeki her piksel temsil çifti arasındaki ikili benzerliği hesaplayarak dikkat haritaları oluşturmaktadır. Bu yaklaşım, modelin girdinin uzamsal bilgisini etkili bir şekilde yakalamasına olanak tanıyarak verilerin daha kapsamlı bir şekilde temsil edilmesini sağlamaktadır. FFN katmanı, ilkinin kanalları genişlettiği (örn. 4 kat), ikincisinin onları ilk boyuta geri küçülttüğü ve arada bir ReLU doğrusal olmayanlığının uygulandığı iki doğrusal dönüşüm katmanından oluşmaktadır. Bu çalışma kapsamında, (Vaswani vd. 2017)'te açıklanan yaklaşıma dayanan Keras'ın Transformer blok uygulaması kullanılmıştır.


Giriş tensörü olarak $x \in \mathbb{R}^{H \times W \times C}$ verildiğinde, Transformer bloğu şu şekilde formüle edilebilmektedir:

$$Transformer(x) = (F \circ M)(x), \quad (\text{Denklem 14})$$

$$M(x) = LayerNorm(x + MHSA(x)), \quad (\text{Denklem 15})$$

$$F(x) = LayerNorm(x + FFN(x)), \quad (\text{Denklem 16})$$

Transformer bloğunun genel yapısı, şekil 3.7'de gösterilmektedir.



Şekil 3.7 Transformer bloğunun genel yapısı


ADT bloğu. Bu blok, CompSegNet mimarisinde kodlayıcıdan gelen özellik haritasında hem yerel hem de küresel bağlam bilgilerini yakalayarak kod çözücüye daha ayrıntılı, yüksek çözünürlüklü uzamsal bilgi ve zengin küresel bağlamsal bilgilerin iletilmesini sağlamak amacıyla özel olarak tasarlanmıştır. Sandglass bloğu, konvolüsyonel işlemler aracılığıyla yerel özellikleri daha etkili bir şekilde yakalarken Transformer blokları, dikkat mekanizmaları sayesinde girdi özellik haritalarında uzun menzilli bağımlılıkları etkili bir şekilde yakalamaktadır.

ADT bloğu, hem konvolüsyonel hem de dikkat tabanlı mekanizmaların güçlü yönlerinden etkili bir şekilde faydalanmak amacıyla, Transformer bloklarını Sandglass bloğunun bir varyantına entegre etmektedir. Daha spesifik olarak ADT bloğu şu şekilde çalışmaktadır: ilk olarak, i -inci kodlama katmanından $f_i \in \mathbb{R}^{H \times W \times C}$ özellik haritası girdi

olarak alınır ve bir 3×3 derinlemesine konvolüsyonuyla filtrelendirir. Ardından bir 1×1 konvolüsyon işlemi uygulanarak özellik haritasının kanal sayısını genişletilir ve $f'_i \in \mathbb{R}^{H \times W \times C'}$ özellik haritası elde edilir; burada $C' = C \times K$ olup K özellik haritasının kanal sayısını genişletme faktörünü göstermektedir. Daha sonra f'_i özellik haritası, $f'_i \in \mathbb{R}^{C' \times HW}$ olarak yeniden şekillendirilir ve L adet Transformer katmanından oluşan bir Transformer yığını uygulanarak konvolüsyon işlemlerinde çıkartılan özellik haritalarında küresel bağlamsal bilgileri yakalanır. Bu işlemin sonucunda elde edilen $g'_i \in \mathbb{R}^{C' \times HW}$ özellik haritası yeniden şekillendirilerek f'_i özellik haritasının başlangıç boyutuna geri getirilir. Ardından Transformer yığını tarafından yakalanan küresel bağlamsal bilgilerini toplamak ve geliştirmek için bir 1×1 konvolüsyon işlemi uygulanarak sonuç özellik haritasının kanal sayısı istenen bir boyuta yansıtılır. Bunun ardında, mevcut özellik haritasındaki karmaşık desenleri yakalamak ve uzamsal boyutunu iki kat azaltmak için adım sayısını 2 kullanan bir 3×3 derinlemesine konvolüsyon işlemi uygulanır. 1×1 konvolüsyon ve 3×3 derinlemesine konvolüsyon katmanları, sinerjik olarak $g''_i \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times C''}$ özellik haritalarını üretmektedir; burada C'' istenen kanal boyutunu göstermektedir. Son olarak, f_i özellik haritası, bir artık bağlantı aracılığıyla çıktı özellik haritasına yayılır ve i -inci ağ katmanında ADT bloğunun çıktı özellik haritası üretilir, $f_{i+1} \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times C''}$.

ADT bloğundaki artık bağlantı, birden fazla amaç için kullanılmaktadır: 1) Önceki kodlayıcı katmanlarında çıkartılan yerel bağlamsal bilgileri koruyarak ve Transformer yığınının sağladığı küresel bağlamsal bilgileri kullanarak bilgi akışını kolaylaştırmak, 2) Transformerlar, uzun menzilli bağımlılıkları yakalama konusunda başarılı olsalar da, özellik haritasındaki bazı desenlerin kaybolmasına ve konumlarının bozulmasına neden olabilmektedir. Bu sorunları önlemek için, dönüştürülmüş özelliklere girdi özelliklerini geri ekleyerek önemli desenlerin yeniden kalibrasyonunu sağlamak, ve 3) sıfırlanan (vanishing) veya uçan (exploding) gradyan sorunlarını hafifleterek eğitim sırasında

gradyan akışını iyileştirmek. ADT bloğu, bloğun optimizasyonunu kolaylaştırmak amacıyla artık bağlantıdan sonra bir ReLU aktivasyon fonksiyonunu uygulamaktadır. Şekil 3.8, ADT bloğunun genel yapısı göstermektedir.



Şekil 3.8 ADT bloğunun genel yapısı

Şekil 3.8'de gösterildiği gibi, ADT bloğu ilk derinlemesine bloğunda varsayılan olarak adım sayısı olarak 1 kullanırken son derinlemesine bloğunda adım sayısı duruma bağlı olarak ayarlanmaktadır. Artık bağlantı, 1×1 konvolüsyon işlemi uygularken adım sayısının son derinlemesine adım sayısı ile aynı olması beklenmektedir. ADT bloğunun detaylı parametreleri ve girdi/çıkı boyutları çizelge 3.3'te verilmiştir.

Çizelge 3.3 ADT bloğunun ayrıntılı parametre ve girdi/çıkı boyutları

Input	Operator	Output
$h \times w \times k$	3×3 dwise, $s = s_1$, BN, ReLU	$\frac{h}{s_1} \times \frac{w}{s_1} \times k$
$\frac{h}{s_1} \times \frac{w}{s_1} \times k$	1×1 conv2d, BN	$\frac{h}{s_1} \times \frac{w}{s_1} \times (tk)$
$\frac{h}{s_1} \times \frac{w}{s_1} \times (tk)$	Reshape	$(tk) \times \frac{hw}{s_1^2}$
$(tk) \times \frac{hw}{s_1^2}$	Transformer, $L = l$	$(tk) \times \frac{hw}{s_1^2}$
$(tk) \times \frac{hw}{s_1^2}$	Reshape	$\frac{h}{s_1} \times \frac{w}{s_1} \times (tk)$
$\frac{h}{s_1} \times \frac{w}{s_1} \times (tk)$	1×1 conv2d, BN, ReLU	$\frac{h}{s_1} \times \frac{w}{s_1} \times k'$
$\frac{h}{s_1} \times \frac{w}{s_1} \times k'$	3×3 dwise, $s = s_2$, BN	$\frac{h}{s_1 \times s_2} \times \frac{w}{s_1 \times s_2} \times k'$

Çizelge 3.3'te, ADT bloğu, $f_i \in \mathbb{R}^{h \times w \times k}$ özellik haritasını $f_{i+1} \in \mathbb{R}^{\frac{h}{s_1 \times s_2} \times \frac{w}{s_1 \times s_2} \times k'}$ özellik haritasına dönüştürmektedir. Çizelgede, basitlik nedeniyle artık bağlantı gösterilmemiştir. Reshape simgesi, özellik haritalarının yeniden şekillendirme işlemini temsil ederken dwise simgesi derinlemesine konvolüsyon işlemini ifade etmektedir. Diğer işlemler ve semboller önceki çizelgelerde kullanılanlarla aynıdır. Bu çalışma kapsamında, s_1 ve s_2 adım sayıları sırasıyla 1 ve 2 olarak ayarlanırken Transformer katman sayısı $L = 6$ ayarlanmıştır. Tüm Transformer katmanları 8 adet kafa kullanmış, FFN'ler ise 0,10'luk bir bırakma (dropout) oranı ve $h_{size} = 1024$ 'lük bir gizli boyut (hidden size) kullanmıştır. Farklı uygulamalarda daha iyi sonuçlar elde etmek için bu parametreler yeniden ayarlanabilmektedir.

3.3 Kayıp Fonksiyonu

Anlamsal segmentasyon, piksel düzeyinde bir sınıflandırma problemi olduğundan, kayıp fonksiyonu, segmentasyon modelinin pikseller arasındaki ince detayları ve

uzamsal ilişkileri doğru bir şekilde yakalamasını sağlamak için tahmin edilen ve gerçek maskelerin uzamsal yapısını dikkate almalıdır.

Literatürde, segmentasyon problemleri için en yaygın kullanılan kayıp fonksiyonları ikili çapraz entropi (BCE) ve Dice katsayısıdır. BCE, piksel bazında sınıflandırma doğruluğunu yakalamak için tahmin edilen olasılıklar ile gerçek ikili etiketler arasındaki farklılığı ölçerken, Dice kayıp fonksiyonu uzamsal benzerliği hesaba katmak için tahmin edilen ve gerçek maskeler arasındaki örtüşmeyi ölçer. Bu iki kayıp fonksiyonunun farklı güçlü ve zayıf yönleri bulunmaktadır. BCE, yerel ayrıntıları yakalama konusunda etkilidir, Dice kaybı ise sınıf dengesizliğini ele alır ve segmentasyon maskelerinde daha fazla küresel tutarlılığı teşvik eder. Ayrıca, BCE, dengesiz bir veri setinde çoğunluk sınıfına doğru bir önyargı gösterebilirken Dice sınıf dengesizliğine karşı daha az hassastır. Bu nedenle, bu çalışmada CompSegNet mimarisinin segmentasyon performansını artırmak için her iki kayıp fonksiyonunun güçlü yönlerinden faydalanarak aşağıdaki gibi bir birleşik kayıp fonksiyonu önerilmiştir:

$$Kayıp = \alpha \cdot BCE \text{ kaybı} + (1 - \alpha) \cdot Dice \text{ kaybı}, \quad (\text{Denklem 22})$$

Burada α , her bir kayıp fonksiyonunun genel kayıp fonksiyonuna göreceli katkısını belirlemek üzere 0 ile 1 arasında bir değerdir. BCE ve Dice kayıp fonksiyonları ise sırasıyla aşağıdaki gibi tanımlanmaktadır:

$$BCE \text{ kaybı} = -g_c(x) \cdot \log(p_c(x)) - (1 - g_c(x)) \cdot \log(1 - p_c(x)), \quad (\text{Denklem 23})$$

$$Dice \text{ Kaybı} = 1 - \frac{2 \Sigma(g_c(x) \cdot p_c(x))}{\Sigma g_c(x) + \Sigma p_c(x)}, \quad (\text{Denklem 24})$$

Burada $p_c(x)$, c sınıfına ait x pikseli için tahmin edilen olasılığı, $g_c(x)$ ise buna karşılık gelen temel gerçek pikselin olasılığını temsil etmektedir.

3.4 Değerlendirme Metrikleri

Bu bölümde, çalışmanın kapsamında geliştirilen mimarilerin nitel değerlendirmesi için kullanılması önerilen değerlendirme metrikleri ayrıntılı bir şekilde açıklanmaktadır.

İkili Doğruluk (Binary Acc). Tahmin edilen örneklerin veri içindeki gerçek örneklerle eşleşme oranıdır:

$$Binary\ Acc = \frac{TP + TN}{TP + TN + FP + FN} , \quad (\text{Denklem 25})$$

Burada TP, TN, FP ve FN sırasıyla doğru pozitifleri, doğru negatifleri, yanlış pozitifleri ve yanlış negatifleri temsil etmektedir.

Ortalama Birleşme Üzerinden Kesişim (MeanIoU). Segmentasyon modellerinin performansını değerlendirmek için yaygın olarak kullanılan bir metriktir. Bu metrik, her sınıf için birleşme üzerinden kesişimi hesaplar, ardından tüm sınıfların ortalamasını alarak tahmin edilen segmentasyon maskesi ile temel gerçek maskesi arasındaki benzerliği ölçmektedir. Tahmin edilen ve gerçek segmentasyon sonuçları arasındaki doğruluk ve örtüşmenin genel bir ölçüsünü sağlamaktadır. MeanIoU metriği aşağıdaki gibi tanımlanmaktadır.

$$MeanIoU = \frac{1}{C} \sum_c \frac{TP_c}{TP_c + FP_c + FN_c} , \quad (\text{Denklem 26})$$

Burada, C sınıf sayısı, c ise ilgili sınıfı temsil etmektedir.

Dice Katsayısı (Dice). Bu metrik, tahmin edilen ve temel gerçek bölgelerinin kesişiminin her iki bölgedeki toplam piksel veya vokselle sayısına oranı olarak hesaplanmaktadır. Aşağıdaki şekilde tanımlanmaktadır:

$$Dice = \frac{2 \times TP}{(TP + FP) + (TP + FN)} , \quad (\text{Denklem 26})$$

Toplanmış Jaccard Endeksi (AJI). Bu metrik, Dikkate alınan tüm gerçek ve segmente edilmiş çekirdekler için birleşik bir kesişim kardinalite paydası sayacı ve birleşik birliktelik kardinalite paydası sayacı hesaplamaktadır. AJI'nin hesaplanması, Jaccard İndeksi'ni maksimize ederek her bir gerçek çekirdeği bir tespit edilen çekirdekle eşleştirme işlemi yaparak gerçekleştirilmektedir. AJI aşağıdaki gibi tanımlanmaktadır:

$$AJI = \frac{\sum_{i=1}^{ng} |G_i \cap S(G_i)|}{\sum_{i=1}^{ng} |G_i \cup S(G_i)| + \sum_{k \in K} |S_k|} , \quad (\text{Denklem 27})$$

Burada ng temel gerçek çekirdek sayısını, G_i temel gerçek çekirdek kümesini, $S(G_i)$ eşleşen bölütlenmiş çekirdek kümesini ve S_k herhangi bir temel gerçek çekirdekle eşleşmeyen bölütlenmiş çekirdek kümesini göstermektedir.

Bu bölümde, CompSegNet mimarisinin ayrıntılı yapısı ve bölüm 2'de yapılan literatür taraması ışığında seçilen temel yapı blokları, bu blokların seçimindeki motivasyon ve CompSegNet mimarisinde kullanılmak üzere bunlara yapılan iyileştirmeler ayrıntılı bir şekilde açıklanmıştır. Ayrıca, CompSegNet mimarisi için özel olarak tasarlanan kayıp fonksiyonu detaylı bir şekilde açıklanmıştır. Son olarak, çalışma kapsamında geliştirilen mimaların nitel değerlendirilmesi için kullanılması önerilen değerlendirme metriklerine dair detaylı bilgi sunulmuştur. Sonraki bölümlerde, CompSegNet mimarisinin uygulanması ve elde edilen bulgularla ilgili ayrıntılı bilgilere yer verilmektedir.

4. COMPSEGNET MİMARİSİNİN UYGULANMASI

Bu bölümde, ilk olarak çalışma kapsamında kullanılan veri setleri ile kullanılan yazılım ve donanımlarla ilgili ayrıntılı bilgiler vermektedir. Ardından CompSegNet mimarisinin uygulanmasıyla ilgili kapsamlı ayrıntılar sunulmaktadır.

4.1 Veri Setleri

Bu çalışma kapsamında MoNuSeg 2018 (Kumar vd. 2020) histopatolojik görüntü veri seti ve Ankara Üniversitesi Patoloji Anabilim Dalı ile Bilgisayar Mühendisliği Anabilim Dalı hocalarının yürüttüğü ortak "Histopatoloji Görüntülerinde Meme Kanseri Tespiti için Derin Öğrenme Tabanlı Metodolojinin Geliştirilmesi" başlıklı TÜBİTAK 1001 projesi (Proje No: 121E379) kapsamında oluşturulan meme kanseri histopatolojik görüntü veri seti kullanılmıştır. Aşağıda ilgili veri setlerine dair açıklamalara yer verilmektedir.


4.1.1 MoNuSeg 2018

Çoklu organ çekirdek segmentasyonu (MoNuSeg) 2018, güncel literatürde çekirdek segmentasyonu çalışmalarında yaygın olarak kullanılan açık kaynaklı bir histopatolojik görüntü veri setidir. Bu veri seti, ilk olarak MoNuSeg 2018 yarışmasında kullanılmış olup Kumar vd. (2020) tarafından tanıtılmıştır. Bu veri seti, $40 \times$ büyütmeyle taranan göğüs, böbrek, karaciğer, prostat, mesane, kolon ve mide olmak üzere yedi farklı organa ait H&E boyalı histopatolojik görüntüleri içermektedir.

MoNuSeg 2018 veri seti, 18 farklı hastaneden farklı hastalara ait bütün slayt görüntülerinin (whole slide image (WSI)) her birinden 1 adet 1000×1000 piksel boyutunda görüntüler olmak üzere toplamda 44 adet görüntüden oluşmaktadır. Veri seti, 30 adet eğitim seti, 14 adet test alt veri setleri olarak bölünmektedir.

Eđitim alt seti, 30 adet g r nt de yaklaşık olarak patolog tarafından manuel olarak etiketlenmiř 21.623  ekirdek yapısı i ermektedir. Test veri setinde ise 14 adet g r nt de aynı protokollerle etiketlenmiř yaklaşık olarak 7.223  ekirdek yapısı bulunmaktadır.

MoNuSeg 2018 veri seti, H&E boyalı histopatolojik g r nt lerde  ekirdek segmentasyonu ve sınıflandırma  zerine odaklanan derin  đrenme modellerinin eđitim ve deđerlendirilmesi i in  nemli bir kaynak sunmaktadır. řekil 4.1, MoNuSeg 2018 veri setine ait  rnek g r nt ler g stermektedir.



řekil 4.1 MoNuSeg 2018 veri setine ait  rnek g r nt ler


4.1.2 NuSeC 2023

 ekirdek Segmentasyonu ve Sınıflandırma (NuSeC) 2023 meme kanseri histopatoloji g r nt  veri seti, Ankara  niversitesi Patoloji Anabilim Dalı ile Bilgisayar M hendisliđi Anabilim Dalı tarafından y r t len "Histopatoloji G r nt lerinde Meme Kanseri Tespiti i in Derin  đrenme Tabanlı Metodolojinin Geliřtirilmesi" (Proje No: 121E379) bařlıklı T B TAK 1001  alıřması kapsamında oluřturulmuřtur. Bu veri seti, Ankara  niversitesi Tıp Patoloji B l m 'nde  zel tip (NST) slaytlar kullanılarak 40 × b y tme ile elde edilen H&E boyalı invaziv meme karsinomu  rneklerini i ermektedir. Slaytlar, 3D Histech Panoramic p250 Flash-3 tarayıcı ve Olympus BX50 mikroskop kullanılarak elde edilmiřtir.

NuSeC 2023 veri seti, 25 hastaya ait bütün slayt görüntülerinin her birinden 4 adet 1024×1024 piksel boyutunda görüntüler olmak üzere toplamda 100 adet görüntüden oluşmaktadır. Veri seti, %75 (75 adet) eğitim ve %25 (25 adet) test alt veri setleri olarak bölünmüştür. Test veri seti, her hastanın bütün slayt görüntülerinden üretilen 4 adet görüntüden birer adet rastgele seçilerek oluşturulmuştur. Eğitim veri seti ise, her hastanın bütün slayt görüntülerinden üretilen 4 adet görüntülerden, test veri seti için rasgele seçilen bir adet görüntü hariç kalan üçer adet görüntüden oluşturulmuştur.

Eğitim veri seti, 75 adet görüntüde yaklaşık olarak 30.000 çekirdek yapısı içermektedir. Test veri setinde ise 25 adet görüntüde yaklaşık olarak 6.000 çekirdek yapısı bulunmaktadır.

NuSeC 2023 veri seti, meme kanseri histopatoloji görüntülerinde çekirdek segmentasyonu ve sınıflandırma üzerine odaklanan derin öğrenme modellerinin eğitim ve değerlendirilmesi için önemli bir kaynak sunmaktadır. Şekil 4.2, NuSeC 2023 veri setine ait örnek görüntüler sunmaktadır.




Şekil 4.2 NuSeC veri setine ait örnek görüntüler

Histopatolojik görüntülerde çekirdek segmentasyonu için güncel literatürde birçok veri seti bulunmaktadır. Bu veri setleri arasında, farklı hastanelerden toplanmış çok sayıda hastalığa ait görüntüleri içeren MoNuSeg 2018, en yaygın kullanılan ve tercih edilen veri setlerinden biridir. Bu nedenle, bu çalışmanın kapsamında geliştirilen mimarilerinin başarısını kanıtlamak amacıyla MoNuSeg 2018 veri seti tercih edilmiştir. Ayrıca,


mimarinin etkinliğini tek bir hastalığa ait görüntülerde değerlendirmek için iyi hazırlanmış olan NuSeC 2023 meme kanseri veri seti tercih edilmiştir. Bir sonraki alt bölümde, geliştirilen mimarilerde kullanılmak üzere bu veri setlerinin ön işlenmesine dair detaylı açıklamalar sunulmaktadır.

4.2 Veri Setlerinin Ön İşlenmesi

Farklı boyama protokolleri ve kaynak değişkenliğinden kaynaklanan histopatoloji görüntülerindeki renk ve yoğunluk varyasyonu, derin öğrenme modellerinin etkinliğini olumsuz yönde etkileyebilmektedir. Bu sorunu ele almak ve geliştirilen mimarilerinin girdi boyutlarına uyum sağlamak amacıyla bölüm 4.2'de belirtilen histopatoloji görüntü veri setleri farklı ön işleme aşamalarına tabi tutulmuştur. İlk olarak, tüm veri setleri Macenko ve arkadaşları (2009) tarafından önerilen boya normalizasyon tekniği kullanılarak normalize edilmiştir. Ardından MoNuSeg 2018 veri setindeki görüntüler, 1000×1000 pikselden 1024×1024 piksele bilinear üst örnekleme yöntemiyle genişletilmiş ve 256×256 piksel boyutunda örtüşmeyen yamalar (patches) çıkartılmıştır. NuSeC 2023 veri setinde ise 1024×1024 piksellik görüntülerden doğrudan 256×256 piksellik örtüşmeyen yamalar çıkarılmıştır. Şekil 4.3 ve şekil 4.4, sırasıyla MoNuSeg 2018 ve NuSeC 2023 veri setlerine dair görüntü normalizasyonu örneklerini göstermektedir. Bu şekillerde, birinci ve ikinci satırlar sırasıyla orijinal ve normalize edilmiş görüntü örneklerini temsil etmektedir.



Şekil 4.3 MoNuSeg 2018 veri setinden normalize edilmiş görüntü örnekleri.



Şekil 4.4 NuSeC 2023 veri setinden normalize edilmiş görüntü örnekleri.

Veri ön işleme, derin öğrenme mimarilerinin başarısı için kritik bir adımdır. Bu alt bölümde, geliştirilen mimarilerin giriş boyutlarına uygun olacak şekilde veri setlerindeki görüntülerden yamalar çıkartılmış ve boya normalizasyonu uygulanmıştır.

Elde edilen görüntülerde (Şekil 4.3 ve Şekil 4.4) gözlemlendiği gibi, renk, yoğunluk ve kontrast varyasyonları dengelemiş, arka plan temizlenerek çekirdeklerin daha belirgin hale gelmesi sağlanmıştır. Bu boya normalizasyonu işlemi, geliştirilen mimarilerin farklı kaynaklardan gelen ve hastalıklara ait H&E boyalı histopatolojik görüntülerdeki renk ve kontrast gibi özelliklerden daha az etkilenmesini ve daha güvenilir sonuçlar üretmesini sağlamaktadır.

4.3 Donanım ve Yazılım Bilgileri

Bu çalışmada önerilen tüm mimariler, Python dilinde backend olarak Tensorflow 2.11'i kullanan Keras derin öğrenme çerçevesi ile geliştirilmiştir. Geliştirme platformu olarak, geliştirilen mimarilerin donanım kaynak gereksinimlerine göre NVIDIA Tesla P100 GPU (16 GB), 2 VCPU ve 25 GB sistem RAM kaynaklarına erişim sağlayan Google Pro örnekleri ile Intel(R) Xeon(R) CPU @ 2.20GHz, 12 CPU çekirdeği ve 40.96 GB GPU belleğine sahip NVIDIA A100-SXM4-40GB GPU ile yaklaşık 90 GB RAM'e sahip Google Colab Pro+ örnekleri kullanılmıştır. Bu hesaplama kaynakları, geliştirilen mimarilerin eğitim ve değerlendirme süreçlerini etkili bir şekilde gerçekleştirmek amacıyla seçilmiştir.

4.4 CompSegNet Mimarisi

CompSegNet mimarisinin uygulanması iki aşamada gerçekleştirilmiştir. İlk aşamada, çekirdek segmentasyonu için temel alınan MBConv bloğunun etkinliği ve bu bloğa yapılan iyileştirmelerin araştırılması amacıyla, CompSegNet mimarisiyle aynı derinliğe sahip olan hafif bir ağ uygulanmıştır. Bu kapsamda hafif ağda temel blok olarak MBConv bloğu ve iyileştirmelerden elde edilen CSeg ve ESeg blokları ayrı ayrı kullanılarak çekirdek segmentasyonundaki performansları değerlendirilmiştir. Her bloğun kullanımı hafif ağın bir varyantını oluşturmuştur. İlgili bloklarda optimum sonuçlar elde edildikten sonra ADT ve GDK bloklarının entegre edilmesiyle CompSegNet mimarisinin farklı varyantları uygulanmıştır. Aşağıda, hafif ağ ve

CompSegNet mimarisinin farklı varyasyonlarının nasıl uygulandığı ile ilgili detaylı açıklamalara yer verilmiştir.

Hafif ağ. Bu çalışma kapsamında MBConv bloğu ve yapılan iyileştirmelerden elde edilen bloklara dayalı olarak hafif ağın dört farklı varyantı uygulanmıştır. İlk varyant (Hafif ağ 1), kodlayıcı, darboğaz ve kod çözücü bölümlerinde yalnızca MBConv bloğunu kullanmaktadır. İkinci varyant (Hafif ağ 2), bu bölümlerde sadece CSeg bloğunu uygulamaktadır. Üçüncü varyant (Hafif ağ 3), bu bölümlerde CSeg ve GC bloğunun birleşimini kullanmaktadır. Dördüncü varyant (Hafif ağ 4) ise bu bölümlerde ECSeg bloğunu kullanmaktadır. Hafif ağın bütün varyantları, kök bloğu olarak tek bir Conv2D katmanını kullanmaktadır. Çizelge 4.1'de, bu varyantların kullandığı bloklar gösterilmektedir.

Çizelge 4.1 Hafif ağ varyantlarının kullandığı temel bloklar

Varyantlar	Kök	Kodlayıcı	Darboğaz	Kod çözücü
Hafif ağ 1	Conv2D	MBConv	MBConv	MBConv
Hafif ağ 2	Conv2D	CSeg	CSeg	CSeg
Hafif ağ 3	Conv2D	CSeg + GC bloğu	CSeg + GC bloğu	CSeg + GC bloğu
Hafif ağ 4	Conv2D	ECSeg	ECSeg	ECSeg

Hafif ağın, MBConv bloğundaki iyileştirmelerin basitleştirilmiş bir ağ mimarisinde değerlendirilmesi amacıyla özel olarak tasarlandığı dikkate alınmalıdır. Bu bağlamda, hafif ağ varyantlarının eğitimi, ayrı bir doğrulama veri seti ayrılmadan eğitim veri setinin tamamının kullanılması ile gerçekleştirilmiştir. Kayıp fonksiyonu olarak yalnızca BCE kullanılmıştır. Özellikle, veri artırma (data augmentation), erken durdurma (Early stopping) ve öğrenme oranı azaltma (learning rate reduction) gibi düzenleme (regularization) teknikleri bilinçli bir şekilde kullanılmamış, böylece yalnızca ağ temelinde yapılan iyileştirmelerin etkilerine odaklanılmıştır. Bu yaklaşım, çekirdek segmentasyonu için MBConv bloğunda yapılan iyileştirmelerin dikkatli bir şekilde izole

edilerek değerlendirilmesini sağlamıştır. Hafif ağın eğitimi ve değerlendirilmesinde uygulanan parametre ayarlarına ilişkin ayrıntılar çizelge 4.2’de sunulmaktadır.

Çizelge 4.2 Hafif ağın parametre ayarları

Parametreler	Değerler
epok sayısı	40
eğitim seti	%100
doğrulama seti	%0
test seti	%100
Küme boyutu	2
Eniyileyici	Adam
Öğrenme oranı	1,00E-03
Kayıp fonksiyonu	BCE

CompSegNet mimarisi. Hafif ağda, çekirdek segmentasyonu için MBConv bloğunda optimum iyileştirmeler elde edildikten sonra CompSegNet mimarisinin uygulanmasına geçilmiştir. Bu bağlamda, önerilen geliştirmelere dayanarak CompSegNet'in dört farklı varyantı oluşturulmuş ve en son ve en gelişmiş varyant ana CompSegNet mimarisi olarak kabul edilmiştir. Aşağıda, CompSegNet varyantlarıyla ilgili açıklamalara yer verilmiş ve ardından bu varyantların kök, kodlayıcı, darboğaz ve kod çözücü bölümlerinde kullanılan blokların ayrıntılı bir şekilde gösterildiği çizelge 4.3 sunulmuştur.

- CompSegNet 1: Bu varyant, kodlayıcı, darboğaz ve kod çözücü bölümlerinde temel blok olarak ECSeg bloğu kullanmaktadır.
- CompSegNet 2: Bu varyant, CompSegNet_1' den farklı olarak kodlayıcı yolunda ilk blok olarak NAS bloğunu kullanmaktadır.

- CompSegNet 3: Bu varyant, CompSegNet_2' den farklı olarak kök blok dışında tüm diğer kodlayıcı bloklarına CSeg bloğunu eklemiştir.
- CompSegNet 4: Son varyant olan bu mimari, CompSegNet_3'den farklı olarak darboğaz bölümünde ECseg yerine RBT bloğunu kullanmaktadır.

Çizelge 4.3 CompSegNet mimarisi varyantlarının kullandığı temel bloklar

Varyantlar	Kök	Kodlayıcı	Darboğaz	Kod çözücü
CompSegNet 1	ECseg	ECseg	ECseg	ECseg
CompSegNet 2	GDK	ECseg	ECseg	ECseg
CompSegNet 3	GDK	CSeg + ECseg	CSeg + ECseg	ECseg
CompSegNet 4	GDK	CSeg + ECseg	ADT	ECseg

Hafif ağın eğitim stratejisinden farklı olarak, CompSegNet mimarilerinin eğitiminde, eğitim veri setlerinin %90'ı eğitim için kullanılmış %10'u ise doğrulama için ayrılmıştır. Kayıp fonksiyonu olarak, bölüm 3.3'te önerilen birleşik kayıp fonksiyonu kullanılmıştır. Ayrıca, modellerin eğitiminde aşırı öğrenmeyi önlemek, CNN'lerde yaygın olarak karşılaşılan dönüşüm eşdeğerlik problemlerini hafifletmek ve modellerin genelleme kabiliyetini artırmak amacıyla erken durdurma, öğrenme oranı azaltma ve veri artırma gibi düzenleme teknikleri kullanılmıştır. Uygulanan veri artırma yöntemleri arasında Gauss filtreleme, medyan filtreleme, kontrast sınırlı uyumlu histogram eşitleme (CLAHE), kabartma, rastgele parlaklık-kontrast ayarları, rastgele kesme, rastgele döndürme, Gauss gürültüsü ekleme, yatay ve dikey translasyon bulunmaktadır. CompSetNet'in eğitiminde kullanılan parametrelerin ayrıntıları çizelge 4.4'te gösterilmektedir.

Çizelge 4.4 CompSegNet mimarilerinin parametre ayarları

Parametreler	Değerler
epok sayısı	başlangıç değeri = 100
eğitim seti	%90
doğrulama seti	%10
test seti	%100
Küme boyutu	8
Eniyileyici	Adam
Öğrenme oranı	1,00E-03
Öğrenme oranı düşürücü	factor = 1,00E-01
	patience = 5
	cooldown = 5
	min_delta = 1e-7
Ağırlık azalması	1,00E-01
Erken Durdurma Düzenleyicisi	min_delta = 0
	patience = 10
	start_epoch = 0
	restore_best_weight = True
Kayıp fonksiyonu	$\alpha = 0.2$

Bu bölümde, CompSegNet mimarisinin uygulanmasıyla ilgili tüm ayrıntılar açıklanmıştır. Çalışma kapsamında kullanılan MoNuSeg 2018 ve NuSeC 2023 histopatolojik görüntü veri setleri, bu veri setlerinin ön işlenmesi, kullanılan yazılım ve donanımlar hakkında detaylı bilgi verilmiştir. CompSegNet mimarisinin uygulanmasına geçmeden önce, çekirdek segmentasyonu için tercih edilen temel blokların standart bir eğitim stratejisi kullanan hafif bir ağda değerlendirilmesi, blokların seçimi ve bu bloklarda gereken iyileştirmelerin sistematik bir şekilde gerçekleştirilmesi sağlanmıştır. Bu bölümde aynı zamanda eğitim stratejileriyle birlikte uygulanan hafif ağı varyantları

ve CompSegNet mimarisinin varyantları detaylı bir şekilde açıklanmıştır. Bir sonraki bölümde, hafif ağıın varyantları ve CompSegNet mimarisinin varyantlarının uygulanmasıyla elde edilen bulgular sunulmakta ve tartışılmaktadır.

5. BULGULAR ve TARTIŞMALAR

Bu bölümde, hafif ağ ve CompSegNet mimarisinin farklı varyantlarının uygulanmasıyla elde edilen bulgular ve tartışmalar sunulmaktadır. İlk olarak hafif ağ varyantlarının MoNuSeg 2018 ve NuSeC 2023 veri setlerindeki uygulanmasına dair değerlendirme metrikleri ve karşılaştırmalı görsel sonuçlar sunularak hafif ağda yapılan iyileştirmelerin etkinliği tartışılmaktadır. Ayrıca bu ağlara dair parametre sayısı ve hesaplama maliyetlerine ilişkin bilgiler de sunulmaktadır. Daha sonra CompSegNet mimarisinin farklı varyantlarının uygulama sonuçları, parametre sayısı, ve hesaplama maliyetleri sunulmakta ve her bir iyileştirmenin etkisi ayrıntılı bir şekilde ele alınmaktadır. Ardından, CompSegNet mimarisinin uygulanmasında önerilen birleşik kayıp fonksiyonunun etkisi incelenmektedir. Son olarak MoNuSeg 2018 veri seti üzerinde CompSegNet mimarisinin performansı, güncel literatürdeki çalışmalar ve MoNuSeg 2018 yarışması sonuçlarıyla karşılaştırılarak kapsamlı bir değerlendirme yapılmaktadır.

5.1 Hafif Ağın Bulguları ve Tartışması

Bu alt bölümün amacı, hafif ağ varyantlarının MoNuSeg 2018 ve NuSeC 2023 veri setleri üzerinde elde ettiği sonuçları sunmak ve tartışmaktır. Bu kapsamda, hafif ağ varyantlarının değerlendirilmesi yapılarak, CSeg ve ESeg bloklarının çekirdek segmentasyonundaki etkinliği ve verimliliği ortaya konulmakta ve temel MBConv bloğuyla kıyasla üstünlükleri gösterilmektedir.

Hafif ağ varyantlarının MoNuSeg 2018 ve NuSeC 2023 veri setlerindeki değerlendirme metrik sonuçları, çizelge 5.1'de, kullanılan donanım kaynakları ve hesaplama maliyetleri ise çizelge 5.2'de sunulmaktadır. Çizelge 5.1'de, koyu ile işaretlenen sonuçlar farklı metrikler için en iyi sonuçları belirtirken, çizelge 5.2'de koyu ile işaretlenen hücreler en yüksek kaynak kullanımını, dolayısıyla en kötü durumu göstermektedir.

Çizelge 5.1 Hafif ağ varyantlarının değerlendirme metrik sonuçları


Varyantlar	MoNuSeg 2018				NuSeC 2023			
	AJI	Dice	MeanIoU	Binary Acc	AJI	Dice	MeanIoU	Binary Acc
Hafif ağ 1	0.631	0.774	0.764	0.913	0.591	0.743	0.725	0.895
Hafif ağ 2	0.655	0.792	0.776	0.914	0.612	0.759	0.739	0.901
Hafif ağ 3	0.666	0.800	0.783	0.917	0.640	0.780	0.756	0.906
Hafif ağ 4	0.674	0.805	0.790	0.922	0.646	0.784	0.761	0.909

Çizelge 5.2 Hafif ağ varyantlarında kullanılan kaynaklar


Varyantlar	Parametre (milyon)	FLOPS (gigabayt)	Eğitim adım süresi (ms/küme)	Çıkarım süresi (ms/görüntü)
Hafif ağ 1	5.74	95.3	533	57
Hafif ağ 2	6.03	47.1	355	40
Hafif ağ 3	6.25	47.2	392	46
Hafif ağ 4	6.68	50.5	402	47

Çizelge 5.1 ve çizelge 5.2'ye göre, Hafif ağ 1'e kıyasla Hafif ağ 2 daha fazla parametre içermesine rağmen, daha kısa sürede daha iyi değerlendirme sonuçları elde etmektedir. Bunun nedeni, Hafif ağ 2'nin Hafif ağ 1'e göre daha düşük saniyede kayan noktalı işlem sayısı (floating point operations per second (FLOPS)) gerektirmesidir. Bu sonuç, CSeg bloğunun (Hafif ağ 2), çekirdek segmentasyonda MBConv bloğuyla (Hafif ağ 1) kıyaslandığında daha etkili ve verimli olduğunu göstermektedir. Hafif ağ 3'te, CSeg bloğu ve GB bloğunun entegrasyonu ile çekirdek segmentasyon performansının AJI skoru olarak MoNuSeg veri setinde 0.655'ten 0.666'ya, NuSeC 2023 veri setinde ise 0.612'den 0.640'a yükseldiği görülmektedir. CSeg ve ICG bloğunun entegrasyonu (ECSeg), Hafif ağ 4'ün performansını MoNuSeg 2018 veri setinde AJI skoru olarak 0.666'dan 0.674'e, Dice skoru olarak 0.800'den 0.805'e, MeanIoU skoru olarak 0.783'ten 0.790'a, Binary Acc skoru olarak 0.917'den 0.922'ye yükselttiği görülmektedir. Aynı şekilde, NuSeC 2023 veri setinde Hafif ağ 4'ün performansı, AJI

skoru olarak 0.640'tan 0.646'ya, Dice skoru olarak 0.780'den 0.784'e, MeanIoU skoru olarak 0.756'dan 0.761'e, Binary Acc skoru olarak 0.906'dan 0.909'a yükseltildiği gözlemlenmektedir. CSeg bloğuna, GC ve IGC bloklarının entegrasyonu nedeniyle Hafif ağ 3 ve Hafif ağ 4'te eğitim adımı ve çıkarım sürelerinde biraz gecikme olsa da, ağların performansını hem verimlilik hem de etkinlik açısından artırmaktadır. Ayrıca Hafif ağ varyantlarının görsel değerlendirmesi için Şekil 5.1 ve Şekil 5.2'de sırasıyla MoNuSeg 2018 ve NuSeC 2023 veri setlerine ait beş örnek yamanın segmentasyon sonuçları sunulmuştur. Şekil 5.1 ve Şekil 5.2'de, her satır, ilgili veri setinin test setinden bir yamanın girdi, temel gerçek (ground truth) ve Hafif ağ varyantlarıyla elde edilen tahmin maskelerini göstermektedir. Ağlar tarafından doğru şekilde sınıflandırılan gerçek pozitif (true positif) pikseller yeşil renkte gösterilirken, yanlış pozitif (false positif) ve yanlış negatif (false negatif) pikseller, ağlar tarafından yanlış sınıflandırılan veya kaçırılan pikseller olarak sırasıyla mavi ve kırmızı renklerle gösterilmiştir. Bu görsel sonuçlara göre, Hafif ağ 1, diğer ağ varyantlarına kıyasla çok sayıda yanlış pozitif piksel içermektedir. Her bir yama için soldan sağa doğru yanlış pozitiflerin ve negatiflerin önemli ölçüde azalma eğiliminde olduğu görülmektedir. Bu nedenle, CSeg (Hafif ağ 2) ve ECSeg (Hafif ağ 4) bloklarının iyi tasarlanmış olduğu ve çekirdek segmentasyonunda MBConv bloğuna (Hafif ağ 1) alternatif olabileceği söylenebilmektedir.



Şekil 5.1 MoNuSeg 2018 veri setinde farklı hafif ağ varyantlarıyla elde edilen segmentasyon sonuçlarına ait örnek görüntüler ve bu sonuçların nicel karşılaştırması



Şekil 5.2 NuSeC 2023 veri setinde farklı hafif ağ varyantlarıyla elde edilen segmentasyon sonuçlarına ait örnek görüntüler ve bu sonuçların nicel karşılaştırması.

5.2 CompSegNet Mimarisinin Bulguları ve Tartışması

Bu alt bölümün amacı, CompSegNet mimarisinin farklı varyantlarının MoNuSeg 2018 ve NuSeC 2023 veri setlerinde elde ettiği sonuçları sunmak ve tartışmaktır. Bu çerçevede, GDK ve ADT bloklarının yanı sıra kodlayıcı bölümünde CSeg ve ECSeg bloklarının birlikte kullanımının etkinlik ve verimlilik açısından değerlendirilmesi yapılarak, bu iyileştirmelerin CompSegNet mimarisi üzerindeki etkisi tartışılmaktadır.

CompSegNet mimarisinin farklı varyantlarının MoNuSeg 2018 ve NuSeC 2023 veri setleri üzerindeki değerlendirme metrik sonuçları, çizelge 5.3'te, kullandıkları kaynaklar ise parametre sayısı, hesaplama maliyeti, eğitim adım süresi ve çıkarım süresi açısından çizelge 5.4'te sunulmaktadır. Çizelge 5.3'te, koyuyla işaretlenen sonuçlar farklı metrikler için en iyi sonuçları gösterirken, çizelge 5.4'de koyuyla işaretlenen hücreler en yüksek kaynak kullanımını, dolayısıyla en kötü durumu göstermektedir.

Çizelge 5.3 CompSegNet mimarisinin varyantlarının değerlendirme metrik sonuçları

	MoNuSeg 2018				NuSeC 2023			
Varyantlar	AJI	Dice	MeanIoU	Binary Acc	AJI	Dice	MeanIoU	Binary Acc
CompSegNet 1	0.691	0.817	0.801	0.926	0.663	0.797	0.772	0.915
CompSegNet 2	0.693	0.819	0.802	0.926	0.664	0.798	0.773	0.915
CompSegNet 3	0.696	0.821	0.804	0.926	0.670	0.802	0.777	0.916
CompSegNet 4	0.704	0.827	0.810	0.930	0.677	0.807	0.781	0.917

Çizelge 5.4 CompSegNet mimarisinin varyantlarında kullanılan kaynaklar

Varyantlar	Parametreler (milyon)	FLOPS (gigabayt)	Eğitim adım süresi (ms/küme)	Çıkarım süresi (ms/görüntü)
CompSegNet 1	6.69	51	176	14
CompSegNet 2	6.7	53.1	181	13
CompSegNet 3	10	80.8	225	15
CompSegNet 4	65.7	154	396	29

GDK bloğunun etkisi. GDK bloğunun etkisini değerlendirmek için CompSegNet mimarisinin birinci ve ikinci (CompSegNet 1 ve CompSegNet 2) varyantları

karşılaştırabilmektedir. CompSegNet 1'de kök bloğu olarak ECSeg bloğu kullanılırken, CompSegNet 2'de GDK bloğu kullanılmaktadır.

Sonuçlardan (çizelge 5.3), GDK bloğunun ECSeg bloğuna kıyasla segmentasyon performansını hafifçe iyileştirdiği gözlemlenmektedir. Bu performans artışına rağmen, GDK bloğu CompSegNet mimarisinde toplam hesaplama maliyetini ve eğitim süresini önemli ölçüde artırmamaktadır. Bunun sebebi, GDK'nın mimariye çok fazla ekstra parametre eklememesidir. Bu sonuçlar, GDK bloğunun tasarlanan CSeg ve ECSeg bloklarıyla karşılaştırıldığında girdi görüntülerindeki olası gürültülere karşı daha etkili olduğunu göstermektedir.

CSeg ve ECSeg bloklarının birlikte kullanımının etkisi. Kodlayıcı ve darboğaz bölümlerinde sırasıyla CSeg ve ECSeg bloklarının uygulanmasının etkisini değerlendirmek için CompSegNet mimarisinin ikinci ve üçüncü varyantları (CompSegNet 2 ve CompSegNet 3) incelenebilmektedir. CompSegNet 2, sadece kodlayıcı ve darboğaz bölümlerinde ECSeg bloğunu kullanırken, CompSegNet 3 ise sırasıyla CSeg ve ECSeg bloklarını uygulamaktadır.


Sonuçlardan CSeg ve ECSeg bloklarının birlikte uygulanmasının, sadece ECSeg'in uygulanmasına kıyasla mimarinin segmentasyon performansını hafifçe artırabileceği görülmektedir. Bununla birlikte bu kombinasyonun ekstra parametre ve hesaplama maliyeti getirdiği belirtilmelidir. Öte yandan CompSegNet 3'ün çıkarım süresinde sadece ekstra 2 milisaniye bir gecikme meydana gelmektedir. Histopatolojide, segmentasyon performansının büyük önem taşıdığı göz önüne alındığında, bu gecikme ihmal edilebilir niteliktedir.

ADT bloğunun etkisi. ADT bloğunun etkisini değerlendirmek için CompSegNet mimarisinin üçüncü ve dördüncü varyantları (CompSegNet 3 ve CompSegNet 4) karşılaştırabilmektedir. CompSegNet 4, darboğaz bölümünde ADT bloğunu kullanırken, CompSegNet 3 ise sırasıyla CSeg ve ECSeg bloklarını uygulamaktadır. Sonuçlardan, ADT bloğunun kullanımıyla CompSegNet 4'ün sırasıyla MoNuSeg 2018 ve NuSeC veri


setlerinde 0.704 ve 0.677 AJI skorları elde ettiği görülmektedir. MoNuSeg 2018 veri seti için elde edilen 0.704 AJI skoru, literatüre göre son derece yüksektir. Yapısı gereği, ADT bloğunun mimariye yüksek hesaplama maliyeti ve gecikme eklediği gözlemlenmektedir. Özellikle eğitim sürecinde her bir küme için yaklaşık 170 milisaniye ekstra gecikme yaşanmaktadır. Ancak, çekirdek segmentasyonunda elde edilen iyileştirmeler göz önüne alındığında, bu durumun makul bir şekilde kabul edilebildiği belirtilmelidir.

Genel performans. Sonuçlar, CompSegNet mimarisinin tüm varyantlarının MoNuSeg 2018 veri setinde 0.69'dan yüksek, NuSeC 2023 veri setinde ise 0.66'dan yüksek bir AJI skoru elde ettiğini göstermektedir. Mimariye GDK ve ADT bloklarının dahil edilmesi, bu skorların MoNuSeg 2018 veri setinde 0.704'e, NuSeC 2023 veri setinde ise 0.677'ye ulaşmasını sağlamıştır. Özellikle MoNuSeg 2018 veri setinde elde edilen 0.704 AJI skoru, literatürdeki çalışmalar ve MoNuSeg 2018 yarışmasının sonuçları ile karşılaştırıldığında, olağanüstü bir başarı olarak değerlendirilebilmektedir.

CompSegNet 1'den CompSegNet 4'e kadar kaynaklar, ek bileşenler nedeniyle artmaktadır. CompSegNet mimarisindeki ek ADT bloğu, büyük bir parametre sayısına ve böylece model karmaşıklığına yol açsa da, bu durum segmentasyon performansının vazgeçilmez önemi nedeniyle göz ardı edilebilmektedir. GDK ve ADT blokların kullanımıyla CompSegNet mimarisinin Etkinliğini daha da kanıtlamak için, şekil 5.3'te MoNuSeg 2018 veri setine, şekil 5.4'te ise NuSeC 2023 ait örnek görsel sonuçlar sunulmuştur. Bu şekillerde, ilk satır histopatolojik görüntülerin örneklerini, ikinci satır ilgili görüntülere ait temel gerçek maskeleri, üçüncü satır ise CompSegNet mimarisiyle elde edilen segmentasyon sonuç maskelerini gösterilmektedir. Segmentasyon sonuç maskeleri, şekil 5.1 ve şekil 5.2 ile aynı renk kodlamasını kullanmaktadır.



Şekil 5.3 MoNuSeg 2018 veri setinde CompSegNet mimarisinin segmentasyon sonuçlarına örnek görseller



Şekil 5.4 NuSeC 2023 veri setinde CompSegNet mimarisinin segmentasyon sonuçlarına örnek görseller

Şekil 5.3 ve şekil 5.4'te görüldüğü gibi, CompSegNet mimarisi, çekirdekleri arka planından başarılı bir şekilde ayırabilmekte ve yüksek kaliteli tahmin maskeleri üretebilmektedir. Genel olarak sonuçlar, CompSegNet mimarisinin MoNuSeg 2018 ve NuSeC 2023 veri setlerinde yüksek performans sergilediğini ve yapılan değişikliklerin segmentasyon performansını daha da iyileştirdiğini göstermektedir.

5.3 Kayıp Fonksiyonundaki Parametrenin Etkisi

Bu alt bölümün amacı, önerilen ortak kayıp fonksiyonundaki parametre ayarlarının etkisini analiz etmektir.

Sonuçlar, çizelge 5.5'te yedi farklı durum için sunulmaktadır, burada beta (β), Bölüm 3.3'te tanımlanan $1 - \alpha$ 'yı ifade etmektedir. CompSegNet mimarisi, MoNuSeg 2018 veri setinde 0.69 veya daha yüksek, NuSeC 2023 veri setinde ise 0.661 veya daha yüksek AJI skorları elde etmektedir. Başka bir deyişle önerilen CompSegNet mimarisi, parametre durumlarından bağımsız olarak tatmin edici sonuçlar elde etmektedir. $\alpha = 1$ ($\beta = 0$) durumunda kayıp fonksiyonu BCE olarak ayarlanmaktadır. Bu durumda mimari MoNuSeg 2018 ve NuSeC veri setlerinde sırasıyla 0.69 ve 0.661 AJI skorlarını elde etmektedir. $\alpha = 0$ ($\beta = 1$) durumunda ise kayıp fonksiyonu Dice olarak ayarlanmaktadır. Bu durumda, mimari MoNuSeg 2018 ve NuSeC veri setlerinde sırasıyla 0.697 ve 0.666 AJI skorlarını elde etmektedir. Başka bir ifadeyle, tek başlarına kullanıldığında, Dice kaybının BCE kaybına kıyasla hafifçe daha iyi performans gösterdiği görülmektedir. Ayrıca, MoNuSeg 2018 veri setinde en yüksek AJI skoru (0.704) $\alpha = 0.2$ ($\beta = 0.8$) parametreleriyle, NuSeC 2023 veri setinde ise en yüksek AJI skoru (0.677) sırasıyla $\alpha = 0.2$ ($\beta = 0.8$) ve $\alpha = 0.4$ ($\beta = 0.6$) parametreleriyle elde edilmiştir. Bu bulgu, önerilen birleşik kayıp fonksiyonunun, BCE veya Dice'nin ayrı ayrı uygulanmasından daha iyi performans sağladığını göstermektedir. Bu avantaj, her iki kaybın özelliklerinin birleştirilmesinden kaynaklanmaktadır.

Çizelge 5.5 Kayıp fonksiyonundaki parametrelerin ayar sonuçları

Parametreler		Veri setleri	
Apha (α)	Beta (β)	MoNuSeg 2018	NuSeC 2023
1.0	0.0	0.690	0.661
0.8	0.2	0.692	0.663
0.6	0.4	0.694	0.665
0.5	0.5	0.699	0.672
0.4	0.6	0.695	0.677
0.2	0.8	0.704	0.677
0.0	1.0	0.697	0.666

5.4 Son Çalışmalarla Karşılaştırmalar

CompSegNet mimarisinin çekirdek segmentasyonundaki etkinliğini daha da kanıtlamak için, çizelge 5.6'te, MoNuSeg 2018 veri seti üzerinde yapılan son çalışmalarla Dice ve AJI metrikleri açısından karşılaştırma sonuçları sunulmaktadır. Bu çizelgede, kullanılan metriklere göre en iyi sonuçlar koyu renkle vurgulanmaktadır.

Sonuçlara göre CompSegNet mimarisi en yüksek AJI skorunu elde ederek çekirdek segmentasyonunda etkinliğini kanıtlamaktadır. Bu, mimarinin çeşitli çekirdeklerin segmentasyonunda etkili olduğunu göstermektedir. CompSegNet aynı zamanda nispeten yüksek bir Dice katsayısına sahiptir, bu da obje sınırlarının başarılı bir şekilde belirlenmesinde etkili olduğunu göstermektedir. Bunun yanı sıra, CI U-Net (Emrah vd. 2023), Dice katsayısı 0.817 olan nispeten yüksek bir AJI skoruna sahiptir, bu da iyi bir sınıf dengesini korurken iyi sınırlama yapabilme yeteneğine sahip olduğunu göstermektedir. GCP-Net (Yang vd. 2022), en yüksek Dice katsayısı skoruna sahip olsa da, AJI skoru açısından CompSegNet ve CI U-Net ile karşılaştırıldığında iyi bir performans sergilememektedir. Ayrıca, CompSegNet ve GCP-Net arasındaki fark, Dice açısından çok düşüktür. TransCUNet (Jiang vd. 2022) ile Lou vd. (2023) tarafından yapılan çalışma, hem Dice hem de AJI skorları açısından benzer sonuçlara sahiptir.


REU-Net (Qin vd. 2022), Dice katsayısı açısından CompSegNet ile benzer sonuçlar elde etmesine rağmen, önemli ölçüde düşük bir AJI skoruna sahiptir. CIA-Net (Zhou vd. 2019), U-Net++ (Zhou vd. 2020) ve RCSAUNET (Wang vd. 2022) modelleri, Dice katsayısı açısından nispeten iyi sonuçlar elde etmelerine rağmen, AJI skorları karşılaştırmalı olarak düşüktür.

Çizelge 5.6 MoNuSeg 2018 veri setinde CompSegNet mimarisinin diğer çalışmalarla karşılaştırılması

Çalışmalar	Dice	AJI
CIA-Net (Zhou vd. 2019)	0.815	0.623
U-Net++ (Zhou vd. 2020)	0.814	0.62
RCSAU-NET (Wang vd. 2022)	0.82	0.619
REU-Net (Qin vd. 2022)	0.826	0.636
TransCUNet (Jiang vd. 2022)	0.8144	0.6459
GCP-Net (Yang vd. 2022)	0.83	0.651
Lou vd (2023)	0.8129	0.6485
CI U-Net (Emrah vd. 2023)	0.817	0.6895
CompSegNet	0.827	0.704

Ayrıca MoNuSeg 2018 veri setinde CompSegNet mimarisiyle elde edilen sonuçlar, MoNuSeg 2018 yarışmasında ilk 14'e giren katılımcıların sonuçlarıyla şekil 5.5'te karşılaştırılmaktadır. CompSegNet, MoNuSeg 2018 veri setinde elde ettiği 0.704 AJI skoruyla, listedeki diğer çalışmalara göre çekirdek segmentasyonunda üstünlüğünü göstermektedir. Bu durum CompSegNet mimarisi tarafından üretilen tahmin segmentasyon maskelerinin gerçek maskelerle yüksek oranda uyumlu olması ve dolayısıyla mimarinin doğruluğunu göstermektedir. CUHK&IMSIGHT ve BUPT.J.LI, sırasıyla 0.6907 ve 0.6868 AJI skorlarıyla ikinci ve üçüncü en doğru yöntemlerdir. Bu yöntemler de tahmin edilen ve gerçek segmentasyon maskeleri arasında yüksek

derecede benzerlik göstermektedir. Tencent AI Lab, listedeki diğer çalışmalara kıyasla en düşük 0.6459 AJI skoruna sahiptir, bu da yöntemin tahmin edilen ve gerçek segmentasyon maskeleri arasında daha düşük bir benzerlik derecesine sahip olduğunu göstermektedir. Genel olarak, bu tez çalışmasında önerilen CompSegNet mimarisi histopatoloji görüntü segmentasyonunda en uygun çerçevelerden (framework) biri olarak değerlendirilebilmektedir.



Şekil 5.5 CompSegNet ile MoNuSeg2018 yarışma sonuçlarının karşılaştırması

6. SONUÇLAR

Histopatolojik görüntüler, tıbbi patolojide çekirdek sayma, çekirdek yoğunluğu tahmini, çekirdek-sitoplazma oranı hesaplama ve nükleer atipi derecelendirme gibi görevleri mümkün kılarak hesaplamalı patolojinin önemli bir rolünü üstlenmektedir. Bu, çekirdek özelliklerinin klinik sonuçları öngörmedeki rolünün araştırılmasında kullanılmaktadır. Örneğin, Lu vd. (2018) erken evre östrojen reseptör pozitif (early-stage estrogen receptor-positive) meme kanserinde sağkalımı tahmin etmek için histoloji doku mikrodizisi (Tissue Microarray (TMA)) örneklerinden çekirdek özelliklerini kullanmıştır. Çekirdek segmentasyonu ve tespitinin otomatikleştirilmesi, patologların iş yükünü azaltmanın yanı sıra tanı ve tedavi planlama süreçlerini kolaylaştırarak kararların doğruluğunu ve tutarlılığını artırmaktadır.

Literatürde, histopatolojik görüntülerde çekirdek segmentasyonunun otomatikleştirilmesine yönelik birçok çalışma yapılmıştır. Bu kapsamda ilk çalışmalar, eşikleme (Gadgil vd. 2016, Phoulady vd. 2016), havza tabanlı (Veta vd. 2011, 2013), graf tabanlı (Xing vd. 2011, Faridi vd. 2016), istatistiksel model (Xu vd. 2011, Taheri vd. 2017) ve aktif konturlar (Naik vd. 2008, Ali ve Madabhushi 2012) gibi geleneksel segmentasyon yöntemlerini kullanmaktadır. Bu yöntemlerin genellikle el yapımı özelliklere dayanması, parametre ayarlarına ve özel çekirdek yapılarına duyarlı olmaları gibi temel kısıtlamaları beraberinde getirmektedir. Bu nedenle bu yöntemlerin histopatolojik görüntüler gibi karmaşık görüntülerde ve büyük ölçekli veri setlerinde uygulanmaları kısıtlıdır.

Güncel literatürde, çekirdek segmentasyonu gibi bilgisayarla görme çalışmalarında derin öğrenme tabanlı yöntemler, karmaşık ilişkileri modelleme ve iyi genelleme yapma gibi yetenekleri nedeniyle yaygın olarak kullanılmaktadır. Bu yöntemlerin büyük bir kısmı, çekirdek segmentasyonu başta olmak üzere birçok tıbbi görüntü analizi çalışmasında tercih edilen ve öne çıkan U-Net mimarisi gibi CNN tabanlı mimarileri kullanmaktadır. Ancak U-Net mimarisi, çoğu CNN tabanlı mimariler gibi aşırı uyma, sınırlı alıcı alan ve görüntü kalitesine duyarlılık gibi sorunlarla karşı karşıya

kalabilmektedir. Bu sorunları ele almak için birçok çalışma yapılmıştır. Bunlar çalışmalardan bazıları, (Wan vd. 2020) gibi histopatolojik görüntülerde çekirdek segmentasyonu için U-Net mimarisine ASPP gibi ekstra modülleri entegre ederek sınırlı alıcı alan sorununu etkili bir şekilde ele almıştır. Bazı çalışmalar ise mimarilerinin görüntüdeki önemli bölgelere odaklanması gibi dikkat mekanizma yöntemlerini kullanmıştır. Bu mimarilere, NucleiSegNet (Lal vd. 2020) ve DEAU (Wang vd. 2022) örnek verilebilmektedir.

Son yıllarda, TransUNet (Chen vd. 2021) ve TransResUNet (Tomar vd. 2022) gibi bazı çalışmalar, biyomedikal görüntü analizi de dahil olmak üzere birçok bilgisayarla görme görevinde, yerel özelliklerin etkin bir şekilde çıkarılmasını sağlamak ve aynı zamanda uzun mesafe bağımlılıklarını yakalamak için CNN mimarilerini Transformer mimarileriyle birleştirmektedir. Bu yaklaşımlar oldukça başarılı sonuçlar elde etmektedir, ancak etkin olabilmeleri için dikkatli bir entegrasyon sürecine ihtiyaç duymaktadır.

Çekirdek segmentasyonu gibi derin öğrenme tabanlı çalışmalarda, uygun bir kayıp fonksiyonunun seçilmesi veya tasarlanması önemli bir husustur. Örneğin, Emrah vd. (2023) çekirdek segmentasyonunda sınıf dengesizliği sorununu ele almak için genelleştirilmiş Dice kaybını (Sudre vd. 2017) kullanmışlardır. Benzer şekilde, (Zhou vd. 2019) gibi bazı çalışmalar, farklı kayıp fonksiyonlarını birleştirerek bu fonksiyonların avantajlarından faydalanmışlardır.

Genel olarak, literatürde sunulan bu yöntemler, çekirdek segmentasyonunda başarılı sonuçların elde edilmesini sağlamış olsa da hala bazı eksiklikleri ve ele alınmamış sorunları bulunmaktadır. Yeterli alıcı alanın sağlanması için eklenen ekstra bloklar veya ekstra kod çözücü yolları kendi hesaplama maliyetlerini getirmekle birlikte bazen etkili olmamaktadır. Transformer mimarileri uzun bağımlılıkları başarılı bir şekilde modelleyebilmelerine rağmen, bu blokların bağımsız olarak kullanılması, özelliklerin konumsal bilgilerinin kaybolmasına neden olabilmektedir. Ayrıca, literatürde girdi

görüntülerde olası gürültülere karşı mimari seviyesinde herhangi bir çözüm ile karşılaşılmamıştır.

Bu tez çalışmasında, H&E boyalı histopatolojik görüntülerde çekirdek segmentasyonu için derin öğrenmeye dayalı yeni bir mimarinin geliştirilmesi amaçlanmıştır. Bu amaç doğrultusunda, literatür taraması sonucunda belirlenen güncel çalışmaların eksiklerini dikkate alarak, çekirdek segmentasyonunu daha doğru ve etkili bir şekilde gerçekleştiren derin öğrenmeye dayalı U-şekilli yeni bir mimari önerilmiştir. Bu mimari, CompSegNet olarak adlandırılmıştır. CompSegNet mimarisi, temel kodlayıcı ve kod çözücü blokları olarak yüksek hesaplama verimliliği, düşük model karmaşıklığı ve yüksek doğruluk sağlama yetenekleriyle bilinen MBConv bloğunu kullanmaktadır. MBConv bloğunun temel blok olarak seçilmesi, CompSegNet mimarisinin düşük bir karmaşıklığa ve dolayısıyla düşük bir hesaplama maliyetine sahip olmasını sağlarken aynı zamanda yüksek hesaplama verimliliği ve genelleme kabiliyeti sunmasına katkıda bulunmuştur.

CompSegNet, U-Net mimarisi başta olmak üzere CNN tabanlı mimarilerin büyük kısmının karşılaştığı sınırlı alıcı alan sorununu etkili bir şekilde ele almak için kullanılan MBConv bloğu için Büyült-Filtrele-Küçült (BFK) adı verilen yeni bir yeterli alıcı alan genişletme yöntemini önermiştir. BFK yöntemi, mimarinin her bir kodlama ve kod çözme aşamasında alıcı alanını yaklaşık sekiz (8) kat genişletmektedir. Bu yöntem, mimarinin başarısını artırmasının yanı sıra çıkarım süresinde yaklaşık %30'luk bir azalma sağlamıştır (çizelge 5.1 ve çizelge 5.2, Hafif ağ 1 ve Hafif ağ 2). Bu kapsamda, elde edilen blok CompSeg (CSeg) bloğu olarak adlandırılmıştır.

Aşırı uyum sorununu ele almak ve mimarinin genelleme yeteneğini artırmak için CSeg bloğuna yeni ve geliştirilmiş bir küresel bağlam (IGC) bloğu entegre edilerek genişletilmiş CompSeg (ECSeg) bloğu oluşturulmuştur. Bu blok, az bir ekstra parametre sayısı ile yüksek düzeyli anlamsal bilgileri yakalayarak ve bağlamsal ilişkileri etkili bir şekilde modelleyerek mimarinin performansını iyileştirmiştir (Çizelge 5.1 ve Çizelge 5.2, Hafif ağ 2 ve Hafif ağ 3).

Mimaride, uzun bağımlılıkların modellenmesi ve özelliklerin konumunun etkili bir şekilde korunması için, darboğaz bölümünde kullanılmak üzere Sanglass ve Transformer bloklarının uygun ve verimli bir şekilde entegre edildiği yeni bir darboğaz bloğu olan Artık Darboğazlı Transformer (ADT) önerilmiştir. Bu blok, yapısı gereği CompSegNet mimarisine ekstra parametre sayısı ve yüksek hesaplama maliyeti getirmektedir (çizelge 5.4). Ancak, çekirdek segmentasyonunda elde edilen iyileştirmeler (çizelge 5.3) göz önüne alındığında, bu durumun makul bir şekilde kabul edilebildiği belirtilmelidir.

CompSegNet mimarisinde, girdi görüntülerinde olası gürültülerin atlama bağlantıları yoluyla kod çözücü yoluna iletilerek mimarilerinin performansını etkileme sorununu hafifletmek için kodlayıcı yolunun ilk bloğu olarak kullanılmak üzere gürültüye duyarlı bir kök (GDK) bloğu önerilmiştir. GDK bloğu, mimarinin en üst seviyesinde, girdi görüntülerinden daha ayrıntılı özellikleri çıkartarak daha temiz ve daha hassas bir özellik çıktısı elde edilmesine katkıda bulunur. Bu sayede, CompSegNet mimarisi gürültülü girdilerle daha iyi başa çıkabilmekte ve daha keskin ve doğru segmentasyon sonuçları üretebilmektedir.

Bu tez çalışmasının başka önemli bir katkısı ise, BCE ve Dice kayıp fonksiyonlarının etkili bir şekilde birleştirilerek CompSegNet mimarisinin performansını artırmasıdır. BCE kayıp fonksiyonu, piksel bazında sınıflandırma doğruluğunu ve yerel ayrıntıları yakalama konusunda etkilidir. Dice kayıp fonksiyonu ise çekirdeklerin uzamsal benzerliğini yakalamak ve sınıf dengesizliği sorunuyla başa çıkmak konusunda etkilidir. Bu nedenle, BCE ve Dice kayıp fonksiyonlarının etkili bir şekilde birleştirilmesi, CompSegNet mimarisinin çekirdek segmentasyonunda daha yüksek performans sergilemesini sağlamaktadır.

Sonuç olarak, CompSegNet mimarisi, çekirdek segmentasyonunda mevcut literatürdeki sınırlamaları etkin bir şekilde ele alarak etkinliğini kanıtlamıştır. MoNuSeg 2018 veri setinde elde edilen 0.704 AJI skoru, güncel literatürde bu veri seti üzerinde yapılan

alışmalar arasında en yksek AJI skoru olmakla birlikte, MoNuSeg 2018 yarıřmasında elde edilen tm sonulardan daha yksektir (řekil 5.5). CompSegNet mimarisi, NuSeC 2023 veri setinde ise 0.677 AJI skorunu elde etmiřtir. Bu skor, MoNuSeg 2018 veri setinde elde edilen AJI skoruna kıyasla daha ok dřk olsa da ekirdek segmentasyonu iin bařarılı olarak kabul edilebilmektedir. Mimarinin bu veri setinde daha dřk bir performans gstermesinin ana nedenlerinden biri, veri setinde ok sayıda ekirdek iermeyen yamaların bulunmasıdır. Bu durumla bařa ıkabilmek iin, nerilen birleřik kayıp fonksiyonuna ek olarak mimarinin uzamsal bilgilerini daha etkili bir řekilde kullanması saėlanmalıdır. Bařka bir husus ise, NuSeC 2023 veri setinin, MoNuSeg 2018 veri setinden farklı olarak yalnızca meme kanseri histopatolojik grntlerini iermesi ve veri setinin kalite kontrol srecinin hala devam etmesidir.

Gelecekte, CompSegNet mimarisinin NuSeC 2023 veri seti zerinde daha yksek sonuları elde etmesine ynelik alışmalar yapılacaktır. Bu kapsamda, uzamsal dikkat mekanizmalarından faydalanabilecektir. Ayrıca, TBTAK 1001 (Proje No: 121E379) projesi kapsamında hazırlanacak olan Mitoz Tespiti, Segmentasyonu ve Sınıflandırması (MiDeSeC) veri seti zerinde CompSegNet mimarisi kullanılarak mitoz segmentasyonu gerekleřtirilecektir. Elde edilecek sonulara gre mimari daha da optimize edilebilecektir.

KAYNAKLAR

- Aatresh, A. A., Yatgiri, R. P., Chanchal, A. K., Kumar, A., Ravi, A., Das, D., Raghavendra, B., Lal, S., ve Kini, J., 2021. Efficient deep learning architecture with dimension-wise pyramid pooling for nuclei segmentation of histopathology images. *Computerized Medical Imaging and Graphics*, 93, 101975.
- Abdel-Nabi, H., Ali, M., Awajan, A., Daoud, M., Alazrai, R., Suganthan, P. N., ve Ali, 2023. A comprehensive review of the deep learning-based tumor analysis approaches in histopathological images: segmentation, classification and multi-learning tasks. *Cluster Computing*, 1-41.
- Albishri, A. A., Shah, S. J. H., Kang, S. S., ve Lee, Y., 2022. AM-UNet: Automated Mini 3D End-to-End U-Net based network for brain claustrum segmentation. *Multimedia Tools and Applications*, 81 (25), 36171-36194.
- Ali, S., ve Madabhushi, A., 2012. An integrated region-, boundary-, shape-based active contour for multiple object overlap resolution in histological imagery. *IEEE Transactions on Medical Imaging*, 31 (7), 1448-1460.
- Alom, M. Z., Yakopcic, C., Taha, T. M., ve Asari, V. K., 2018. Nuclei segmentation with recurrent residual convolutional neural networks based U-Net (R2U-Net). In *IEEE National Aerospace and Electronics Conference (NAECON2018)*, 228-233. IEEE.
- Basu, A., Senapati, P., Deb, M., Rai, R., ve Dhal, K. G., 2023. A survey on recent trends in deep learning for nucleus segmentation from histopathology images. *Evolving Systems*.
- Ba, J. L., Kiros, J. R., ve Hinton, G. E., 2016. Layer normalization. *arXiv preprint arXiv:1607.06450*.
- Cao, Y., Xu, J., Lin, S., Wei, F., ve Hu, H., 2019. Gcnet: Non-local networks meet squeeze-excitation networks and beyond. In *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*.
- Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., Lu, L., Yuille, A. L., ve Zhou, Y., 2021. TransUNet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*.

- Chidester, B., Ton, T. V., Tran, M. T., Ma, J., ve Do, M. N., 2019. Enhanced rotation-equivariant U-Net for nuclear segmentation. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops.
- Faridi, P., Danyali, H., Helfroush, M. S., ve Jahromi, M. A., 2016. An automatic system for cell nuclei pleomorphism segmentation in histopathological images of breast cancer. In IEEE Signal Processing in Medicine and Biology Symposium (SPMB2016), 1-5. IEEE.
- Gadgil, N. J., Salama, P., Dunn, K. W., ve Delp, E. J., 2016. Nuclei segmentation of fluorescence microscopy images based on midpoint analysis and marked point process. In IEEE Southwest Symposium on Image Analysis and Interpretation (SSIAI2016), 37–40. IEEE.
- Hancer, E., Traoré, M., Samet, R., Yıldırım, Z., ve Nemati, N., 2023. An imbalance-aware nuclei segmentation methodology for H&E stained histopathology images. Biomedical Signal Processing and Control, 83, 104720.
- Hendrycks, D., ve Gimpel, K., 2016. Gaussian error linear units (GELUs). arXiv preprint arXiv:1606.08415.
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., ve Vasudevan, V., 2019. Searching for mobilenetv3. In Proceedings of the IEEE/CVF international conference on computer vision (ICCV2019), 1314–1324.
- Hu, J., Shen, L., ve Sun, G., 2018. Squeeze-and-excitation networks. In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR2018), 7132-7141.
- Ioffe, S., ve Szegedy, C., 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In International Conference on Machine Learning, 448-456.
- Jevtic, P., Edens, L. J., Vukovic, L. D., ve Levy, D. L., 2014. Sizing and shaping the nucleus: mechanisms and significance. Current Opinion in Cell Biology, 28, 6–27.
- Jiang, S., ve Li, J., 2022. Transcunet: Unet cross-fused transformer for medical image segmentation. Computers in Biology and Medicine, 150, 106207.
- Jierong, C., ve Rajapakse, J.C., 2009. Segmentation of clustered nuclei with shape markers and marking function, IEEE Transactions on Biomedical Engineering, 56 (3), 741-748.
- Jung, H., Lodhi, B., ve Kang, J., 2019. An automatic nuclei segmentation method based

- deep convolutional neural networks for histopathology images. *BMC Biomedical Engineering*, 1 (1), 1-12.
- Kimura, H., ve Yonemura, Y., 1991. Flow cytometric analysis of nuclear dna content in advanced gastric cancer and its relationship with prognosis. *Cancer*, 67 (10), 2588–2593.
- Kiran, I., Raza, B., Ijaz, A., ve Khan, M. A., 2022. DenseRes-UNet: Segmentation of overlapped/clustered nuclei from multi-organ histopathology images. *Computers in Biology and Medicine*, 143, 105267.
- Kumar, N., Verma, R., Anand, D., Zhou, Y., Onder, O. F., Tsougenis, E., Chen, H., Heng, P.-A., Li, J., Hu, Z., Wang, Y., Koohbanani, N. A., Jahanifar, M., Tajeddin, N. Z., Gooya, A., Rajpoot, N., Ren, X., Zhou, S., Wang, Q., Shen, D., Yang, C.-K., Weng, C.-H., Yu, W.-H., Yeh, C.-Y., Yang, S., Xu, S., Yeung, P. H., Sun, P., Mahbod, A., Schaefer, G., Ellinger, I., Ecker, R., Smedby, O., Wang, C., Chidester, B., Ton, T.-V., Tran, M.-T., Ma, J., Do, M. N., Graham, S., Vu, Q. D., Kwak, J. T., Gunda, A., Chunduri, R., Hu, C., Zhou, X., Lotfi, D., Safdari, R., Kascenas, A., O'Neil, A., Eschweiler, D., Stegmaier, J., Cui, Y., Yin, B., Chen, K., Tian, X., Gruening, P., Barth, E., Arbel, E., Remer, I., Ben-Dor, A., Sirazitdinova, E., Kohl, M., Braunewell, S., Li, Y., Xie, X., Shen, L., Ma, J., Bakshi, K. D., Khan, M. A., Choo, J., Colomer, A., Naranjo, V., Pei, L., Iftekharruddin, K. M., Roy, K., Bhattacharjee, D., Pedraza, A., Bueno, M. G., Devanathan, S., Radhakrishnan, S., Koduganty, P., Wu, Z., Cai, G., Liu, X., Wang, Y., ve Sethi, A., 2020. A multi-organ nucleus segmentation challenge. *IEEE Transactions on Medical Imaging*, 39 (5), 1380-1391.
- Lal, S., Das, D., Alabhya, K., Kanfode, A., Kumar, A., ve Kini, J., 2021. Nucleisegnet: robust deep learning architecture for the nuclei segmentation of liver cancer histopathology images. *Computers in Biology and Medicine*, 128, 104075.
- Li, Y., Sun, L., Xia, N., Peng, R., Tang, K., Zeng, G., ve Wang, S., 2021. Anatomy-guided parallel bottleneck transformer network for automated evaluation of root canal therapy. *arXiv preprint arXiv*, 2105.
- Lou, W., Li, H., Li, G., Han, X., ve Wan, X. (2023). Which pixel to annotate: A label-efficient nuclei segmentation framework. *IEEE Transactions on Medical Imaging*, 42 (4), 947-958.
- Lu, C., Romo-Bucheli, D., Wang, X., Janowczyk, A., Ganesan, S., Gilmore, H., Rimm, ve Madabhushi, A., 2018. Nuclear shape and orientation features from h&e images predict survival in early-stage estrogen receptor-positive breast cancers. *Laboratory Investigation*, 98 (11), 1438.

- Ma, N., Zhang, X., Zheng, H.-T., ve Sun, J., 2018. Shufflenetv2: Practical guidelines forefficient cnn architecture design. In Proceedings of the European conference on computer vision (ECCV2018), 116–131.
- Mehta, S., Hajishirzi, H., ve Rastegari, M., 2020. Dicenet: Dimension-wise convolutions for efficient networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 44 (5), 2416–2425.
- Naik, S., Doyle, S., Agner, S., Madabhushi, A., Feldman, M., ve Tomaszewski, J., 2008. Automated gland and nuclei segmentation for grading of prostate and breast cancer histopathology. In: IEEE International Symposium on Biomedical Imaging: From Nano to Macro, 284-287
- Nair, V., ve Hinton, G. E., 2010. Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th International Conference on Machine Learning (ICML2010), 807-814.
- Nodirov, J., Abdusalomov, A. B., ve Whangbo, T. K., 2022. Attention 3D U-Net with multiple skip connections for segmentation of brain tumor images. Sensors, 22 (17), 6501.
- Pan, S., Liu, X., Xie, N., ve Chong, Y., 2023. EG-TransUNet: a transformer-based U-Net with enhanced and guided models for biomedical image segmentation. BMC bioinformatics, 24 (1), 85.
- Pandey, S., Singh, P. R., ve Tian, J., 2020. An image augmentation approach using two-stage generative adversarial network for nuclei image segmentation. Biomedical Signal Processing and Control, 57, 101782.
- Phoulady, H. A., Zhou, M., Goldgof, D. B., Hall, L. O., ve Mouton, P. R., 2016. Automatic quantification and classification of cervical cancer via adaptive nucleus shape modeling. In IEEE International Conference on Image Processing (ICIP2016), 2658–2662. IEEE.
- Protonotarios, N. E., Katsamenis, I., Sykiotis, S., Dikaïos, N., Kastis, G. A., Chatziioannou, S. N., Metaxas, M., Doulamis, N., ve Doulamis, A., 2022. A few-shot U-Net deep learning model for lung cancer lesion segmentation via PET/CT imaging. Biomedical Physics & Engineering Express, 8 (2), 025019.
- Qi, X., Xing, F., Foran, D. J., ve Yang, L., 2012. Robust segmentation of overlappingcells in histopathology specimens using parallel seed detection and repulsive level set. IEEE Transactions on Biomedical Engineering, 59 (3), 754-765.

- Qin, J., He, Y., Zhou, Y., Zhao, J., ve Ding, B., 2022. Reu-net: Region-enhanced nuclei segmentation network. *Computers in Biology and Medicine*, 146, 105546.
- Ronneberger, O., Fischer, P., ve Brox, T., 2015. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, 234-241. Springer.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., ve Chen, L.-C., 2018. Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR2018)*, 4510–4520.
- Springenberg, J. T., Dosovitskiy, A., Brox, T., & Riedmiller, M., 2014. Striving for simplicity: The all convolutional net. *arXiv preprint arXiv:1412.6806*.
- Srinivas, A., Lin, T. Y., Parmar, N., Shlens, J., Abbeel, P., ve Vaswani, A., 2021. Bottleneck transformers for visual recognition. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 16519-16529.
- Sudre, C. H., Li, W., Vercauteren, T., Ourselin, S., ve Jorge Cardoso, M., 2017. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Proceedings 3*, 240-248, Canada.
- Tai, Y., Yang, J., ve Liu, X., 2017. Image super-resolution via deep recursive residual network. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR2017)*, 3147-3155.
- Taheri, S., Fevens, T., ve Bui, T.D., 2017. Robust nuclei segmentation in cyto-histopathological images using statistical level set approach with topology preserving constraint. In *SPIE Medical Imaging*, 1013318.
- Tan, M., Chen, B., Pang, R., Vasudevan, V., Sandler, M., Howard, A., ve Le, Q. V., 2019. Mnasnet: Platform-aware neural architecture search for mobile. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR2019)*, 2820-2828.
- Tan, M. ve Le, Q., 2019. Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, 6105–6114, PMLR.

- Tomar, N. K., Shergill, A., Rieders, B., Bagci, U., ve Jha, D., 2022. TransResU-Net: Transformer based ResU-Net for Real-Time Colonoscopy Polyp Segmentation. arXiv preprint arXiv:2206.08985.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., Polosukhin, I., 2017. Attention is all you need. In *Advances in Neural Information Processing Systems*, (30).
- Veta, M., Huisman, A., Viergever, M. A., van Diest, P. J., ve Pluim, J. P., 2011. Marker-controlled watershed segmentation of nuclei in H&E stained breast cancer biopsy images. In *IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, 618-621. IEEE.
- Veta, M., Van Diest, P. J., Kornegoor, R., Huisman, A., Viergever, M. A., ve Pluim, J., 2013. Automatic nuclei segmentation in H&E stained breast cancer histopathology images. *PloS one*, 8 (7), e70221.
- Wan, T., Zhao, L., Feng, H., Li, D., Tong, C., ve Qin, Z., 2020. Robust nuclei segmentation in histopathology using ASPPU-Net and boundary refinement. *Neurocomputing*, 408, 144-156.
- Wang, T., Lei, Y., Fu, Y., Wynne, J. F., Curran, W. J., Liu, T., ve Yang, X., 2021. A review on medical imaging synthesis using deep learning and its clinical applications. *Journal of applied clinical medical physics*, 22 (1), 11-36.
- Wang, H., Xu, G., Pan, X., Liu, Z., Lan, R., ve Luo, X., 2022. Multi-task generative adversarial learning for nuclei segmentation with dual attention and recurrent convolution. *Biomedical Signal Processing and Control*, 75, 103558.
- Xing, F., Xie, Y., ve Yang, L., 2016. An Automatic Learning-Based Framework for Robust Nucleus Segmentation. *IEEE Trans. Med. Imaging* 35 (2), 550-566.
- Xu, J., Janowczyk, A., Chandran, S., ve Madabhushi, A., 2011. A high-throughput active contour scheme for segmentation of histopathological imagery. *Medical Image Analysis*, 15 (6), 851-862.
- Xu, J., Monaco, J.P., Sparks, R., ve Madabhushi, A., 2017. Connecting Markov Random Fields and Active Contour Models: Application to Gland Segmentation and Classification. *J. Med. Imaging* 4 (2), 21107.
- Yang, G., Huang, J., He, Y., Chen, Y., Wang, T., Jin, C., ve Sengphachanh, P., 2022. GCP-Net: A Gating Context-Aware Pooling Network for Cervical Cell Nuclei Segmentation. *IEEE Transactions on Medical Imaging*.

- Yang, X., Li, H., ve Zhou, X. 2006. Nuclei Segmentation Using Marker-Controlled Watershed, Tracking Using Mean-Shift, and Kalman Filter in Time-Lapse Microscopy. *IEEE Trans. Circuits Syst. I Regul. Pap.*, 53 (4), 2405–2414.
- Yang, C., Qiao, S., Yu, Q., Yuan, X., Zhu, Y., Yuille, A., Adam, H., ve Chen, L.-C., 2022. Moat: Alternating mobile convolution and attention brings strong vision models. *arXiv preprint arXiv:2210.01820*.
- Yildirim, Z., Hancer, E., Samet, R., Mali, M. T., ve Nemati, N., 2022. Effect of color normalization on nuclei segmentation problem in H&E stained histopathology images. In *30th Signal Processing and Communications Applications Conference (SIU2022)*, 1-4.
- Zeng, Z., Xie, W., Zhang, Y., ve Lu, Y., 2019. Ric-UNet: An improved neural network based on U-Net for nuclei segmentation in histology images. *IEEE Access*, 7, 21420-21428.
- Zhang, D., Song, Y., Liu, S., Feng, D., Wang, Y., ve Cai, W., 2018. Nuclei instance segmentation with dual contour-enhanced adversarial network. In *15th IEEE International Symposium on Biomedical Imaging (ISBI2018)*, 409-412, IEEE.
- Zhang, X., Zhou, X., Lin, M., ve Sun, J., 2018. Shufflenet: An extremely efficient convolutional neural network for mobile devices. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR2018)*, 6848–6856.
- Zhou, D., Hou, Q., Chen, Y., Feng, J., ve Yan, S., 2020. Rethinking bottleneck structure efficient mobile network design. In *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part III*, 16, 680–697, Springer.
- Zhou, Y., Onder, O. F., Dou, Q., Tsougenis, E., Chen, H., ve Heng, P.-A., 2019. Cianet: Robust nuclei instance segmentation with contour-aware information aggregation. In *Information Processing in Medical Imaging: 26th International Conference, (IPMI2019), Hong Kong, China, June 2–7, 2019, Proceedings 26*, 682–693, Springer.