



**DERİN ÖĞRENME YAKLAŞIMLARIYLA RADYOLOJİK
GÖRÜNTÜLERİN BÖLÜTLENMESİ VE
SINIFLANDIRILMASI: KLİNİK BİR UYGULAMA**

Hüseyin KUTLU

BİYOİSTATİSTİK VE TIP BİLİŞİMİ ANABİLİM DALI

**Tez Danışmanı
Prof. Dr. Cemil ÇOLAK**

Doktora Tezi – 2025

**T.C.
İNÖNÜ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME YAKLAŞIMLARIYLA RADYOLOJİK
GÖRÜNTÜLERİN BÖLÜTLENMESİ VE SINIFLANDIRILMASI: KLİNİK BİR
UYGULAMA**

Hüseyin KUTLU

Biyoistatistik ve Tıp Bilişimi Anabilim Dalı

Doktora Tezi

**Tez Danışmanı
Prof. Dr. Cemil ÇOLAK**

**Tez Jüri Üyeleri
Prof. Dr. Cemil ÇOLAK
Prof. Dr. Hakan PARLAKPINAR
Prof. Dr. Memiş BOLACALI
Doç. Dr. Emek GÜLDOĞAN
Doç. Dr. Mehmet Onur KAYA**

**MALATYA
2025**

KABUL VE ONAY



T.C.
İNÖNÜ ÜNİVERSİTESİ
Sağlık Bilimleri Enstitüsü Müdürlüğüne

ETİK BEYANI

İnönü Üniversitesi Sağlık Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak “Prof. Dr. Cemil ÇOLAK” danışmanlığında hazırlayıp sunduğum “Derin Öğrenme Yaklaşımlarıyla Radyolojik Görüntülerin Bölütlenmesi ve Sınıflandırılması: Klinik Bir Uygulama“ başlıklı Doktora tezim içinde elde ettiğim verileri, bilgileri, belgeleri akademik ve etik kurallar çerçevesinde elde ettiğimi, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tezimde yararlandığım eserlere bilimsel kurallara uygun atıfta bulunarak kaynak gösterdiğimi, tezimin özgün olduğunu, tezimin çalışma ve yazımında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

09 / 05/ 2025

Hüseyin KUTLU, İmza

İÇİNDEKİLER

ÖZET	ix
ABSTRACT	x
SİMGELER VE KISALTMALAR DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
TABLolar DİZİNİ	xiv
1. GİRİŞ	1
2. GENEL BİLGİLER	7
2.1. Radyolojik Görüntüleme Modaliteleri	7
2.1.1. Ultrason	7
2.1.2. Manyetik Rezonans Görüntüleme (MR)	8
2.1.3. Bilgisayarlı Tomografi (BT)	8
2.2. Derin Öğrenme Yaklaşımı ile Görüntü Bölütleme	8
2.2.1. U-Net	9
2.2.2. SegNet	10
2.2.3. DeepLab v3+	11
2.2.4. Mask R-CNN	11
2.2.5. Attention U-Net	12
2.2.6. U-Net++	13
2.2.7. TransUNet	14
2.2.8. Swin- Unet	15
2.2.9. Vision Mamba UNet	16
2.3. Derin Öğrenme Algoritmaları ile Görüntü Sınıflandırma	17
2.3.1. CNN Modelleri ile Sınıflandırma	17
2.3.2. Vision Transformer ile Sınıflandırma	18
2.3.3. Swin Transformer ile Sınıflandırma	18
2.4. Karotid Arter Hastalığı	19
2.5. Meme Kanseri	20
3. MATERYAL VE METOT	21
3.1. Veri Setleri	21
3.1.1. Karotid Arter Veri Seti	21
3.1.2. Meme Lezyonu Veri Seti	21

3.1.3. Veri Setlerinin Bölünmesi ve Hazırlanması.....	22
3.2. Veri Ön İşleme ve Veri Artırma	22
3.3. Modellerin Eğitimi ve Optimizasyon Yöntemleri	23
3.3.1. U-Net.....	23
3.3.2. SegNet.....	23
3.3.3. DeepLab v3+.....	23
3.3.4. Mask R-CNN	23
3.3.5. Attention U-Net.....	23
3.3.6. U-Net++	24
3.3.7. TransUNet.....	24
3.3.8. Swin U-Net	24
3.3.9. Vision Mamba UNet	24
3.3.10. Sınıflandırma Algoritmaları	25
3.4. Performans Metrikleri	25
3.4.1. Dice Benzerlik Katsayısı (DSC)	25
3.4.2. Kesişim Bölgesi Oranı (IoU)	25
3.4.3. Hassasiyet (Sensitivity/Recall)	26
3.4.4. Özgüllük (Specificity).....	26
3.4.5. Doğruluk (Accuracy)	27
3.4.6. Kesinlik (Precision).....	27
3.4.7. PA (Piksel Doğruluğu – Pixel Accuracy)	28
3.4.8. F1 Skoru	28
3.5. Meme Lezyon Görüntülerini Bölütleme ve Sınıflandırma Yazılımı	28
3.5.1. Yazılım Mimarisi	28
3.5.2. Yazılım Özellikleri.....	29
3.5.3. Yazılım İş Akışı	29
3.5.4. Model Optimizasyonu ve Dağıtımı.....	30
3.6. Karotid Arter Ultrason İmgelerini Bölütleme Yazılımı	32
3.6.1. Yazılım Mimarisi	33
3.6.2. Yazılım Özellikleri.....	33
3.6.3. Yazılım İş Akışı	34
3.6.4. Model Optimizasyonu ve Dağıtımı.....	34
4. BULGULAR	37
4.1. İki Boyutlu Karotid Arter Ultrason Veri Seti Üzerindeki Bulgular.....	37

4.1.1. CCA Veri Seti Bulguları	37
4.2. İki Boyutlu Meme Lezyon Veri Seti Üzerindeki Bulguları	38
4.2.1. BUSI Veri Seti Bölütleme Bulguları	38
4.2.2. BUSI Veri Seti Sınıflandırma Bulguları	40
5. TARTIŞMA	42
6. SONUÇ VE ÖNERİLER	45
KAYNAKLAR	45
EKLER	51
EK-1. Özgeçmiş	51
EK-2. Etik Kurul Onayı	52



TEŞEKKÜR

Akademik yolculuğumun en önemli aşamalarından biri olan doktora eğitimim boyunca bilimsel bakış açısı, engin bilgi birikimi ve değerli yönlendirmeleriyle bana rehberlik eden tez danışmanım Prof. Dr. Cemil ÇOLAK'a içtenlikle teşekkürlerimi sunarım. Kendisinin sabırlı ve destekleyici yaklaşımı, tez çalışmamın ve akademik çalışmalarımın her aşamasında bana güç vermiştir.

Biyoistatistik ve Tıp Bilişimi Anabilim Dalı'ndaki değerli hocalarım Prof. Dr. Harika Gözde GÖZÜKARA BAĞ, Doç. Dr. Emek GÜLDOĞAN ve Dr. Öğr. Üyesi Ahmet Kadir ARSLAN'a ve bölümdeki tüm akademisyenlere, eğitim sürecim boyunca sağladıkları bilimsel destek ve katkılarından dolayı minnettarım.

Doktora sürecinde karşılaştığım zorlukları aşmamda yardımcı olan ve desteğini hiçbir zaman esirgemeyen değerli arkadaşım Öğr. Gör. Abdulvahap PINAR'a özel teşekkürlerimi sunarım.

Hayatımın her anında yanımda olan, sevgisini ve desteğini her zaman hissettiğim değerli eşim Emine ŞAHİN KUTLU'ya zor zamanlarımda hep yanımda olan ağabeylerime ve varlığıyla yaşamıma anlam katan, sevgili oğlum Ahmet Şahin KUTLU'ya sonsuz teşekkürlerimi sunarım.

6 Şubat 2023 depreminde kaybettiğim, bugünlere gelmemde büyük emekleri olan değerli annem Aysel KUTLU ve babam İbrahim Üryan KUTLU'ya en derin minnettarlığımı ifade etmek isterim. Onların hayalleri ve öğretileri, akademik çalışmalarım da bana ışık tutmuştur.

Hüseyin KUTLU

ÖZET

Derin Öğrenme Yaklaşımlarıyla Radyolojik Görüntülerin Bölütlenmesi ve Sınıflandırılması: Klinik Bir Uygulama

Amaç: Bu çalışmada üç aşama izlenmiştir. İlk olarak, farklı derin öğrenme mimarilerinin bölütleme ve sınıflandırma performansları karşılaştırılmıştır. İkinci aşamada, en etkili algoritmalar tespit edilmiştir. Son olarak, belirlenen algoritmalar kullanılarak biri karotid arter yapısının radyolojik görüntülerden otomatik bölütlenmesini, diğeri ise meme lezyonlarının otomatik bölütlenmesini ve sınıflandırılmasını gerçekleştiren iki ayrı klinik karar destek sistemi geliştirilmiştir.

Materyal ve Metot: Çalışmada, meme ultrason görüntüleri ve karotid arter ultrason görüntülerinden oluşan iki veri seti kullanılmıştır. Bu veri setleri üzerinde, U-Net, SegNet, DeepLab v3+, Mask R-CNN, Attention U-Net, U-Net++, TransUNet, Swin-Unet ve Vision Mamba UNet olmak üzere dokuz farklı derin öğrenme mimarisinin bölütleme performansları karşılaştırılmıştır. Performans değerlendirmesinde ise DSC, IoU gibi metrikler kullanılmıştır. Ayrıca meme ultrason görüntüleri dokuz farklı CNN modeli ve Swin-Transformer ve Vision-Transformer ile sınıflandırılmıştır. Performansı en yüksek bölütleme ve sınıflandırma algoritmaları tez kapsamında geliştirilen web tabanlı klinik uygulamalarda kullanılmıştır.

Bulgular: Vision Mamba UNet tüm veri setleri üzerinde en yüksek bölütleme performansını göstermiştir. Vision Mamba UNet, ortalama 0.943 DSC ve 0.896 IoU metrik değerleri elde ederken; Swin UNet de benzer bir performans sergilemiştir. Vision Transformer 88.7 f1 değeri ile sınıflandırma konusunda öne çıkmıştır. Vision Mamba UNet ve Vision Transformer ile geliştirilen karotid arter bölütlemesi ve meme ultrason görüntülerinden lezyon bölütleme ve sınıflandırma web uygulamalarından, kullanım kolaylığı, hız ve doğruluk açısından olumlu sonuçlar alınmıştır.

Sonuç: Geliştirilen web uygulamaları; klinik karar süreçlerine dahil edilebilecek, radyologların iş yükünü azaltarak tanı sürecini hızlandırabilecek ve hassasiyetini artıracak potansiyele sahiptir.

Anahtar Kelimeler: Derin öğrenme, Karotid arter bölütleme, Klinik karar destek sistemi, Meme lezyonu bölütleme ve sınıflandırma.

ABSTRACT

Segmentation and Classification of Radiological Images with Deep Learning Approaches: A Clinical Application

Aim: This study was carried out in three stages. First, the segmentation and classification performances of various deep learning architectures were compared. In the second stage, the most effective algorithms were identified. Finally, two separate clinical decision-support systems were developed using the selected algorithms—one for automatic segmentation of the carotid artery structure from radiological images, and the other for automatic segmentation and classification of breast lesions.

Materials and Methods: Two datasets were used: breast ultrasound images and carotid artery ultrasound images. On these datasets, nine deep learning architectures U-Net, SegNet, DeepLab v3+, Mask R-CNN, Attention U-Net, U-Net++, TransUNet, Swin-Unet, and Vision Mamba UNet were compared in terms of segmentation performance. Dice Similarity Coefficient (DSC) and Intersection over Union (IoU) metrics were employed for performance evaluation. Additionally, the breast ultrasound images were classified using nine different CNN models as well as Swin Transformer and Vision Transformer. The segmentation and classification algorithms that achieved the highest performance were then integrated into the web-based clinical applications developed for this thesis.

Results: Vision Mamba UNet demonstrated the highest segmentation performance across both datasets, achieving an average DSC of 0.943 and an IoU of 0.896; SwinUNet showed similarly strong performance. For classification, Vision Transformer stood out with an F1 score of 88.7. The web applications based on Vision Mamba UNet and Vision Transformer—for carotid artery segmentation and breast lesion segmentation/classification, respectively—yielded positive feedback in terms of ease of use, speed, and accuracy.

Conclusion: The developed web-based applications have the potential to be incorporated into clinical decision workflows, reducing radiologists' workload, accelerating the diagnostic process, and improving diagnostic accuracy.

Keywords: Breast lesion segmentation and classification, Carotid artery segmentation, Clinical decision support system, Deep learning.

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay Zeka)
ASPP	: Atrous Spatial Pyramid Pooling
BT	: Bilgisayarlı Tomografi
BTA	: Bilgisayarlı Tomografi Anjiyografi
BUSI	: Meme Ultrason Görüntüsü Veri Seti (Breast Ultrason Image)
CCA	: Common Carotid Artery (Ortak Karotid Arter)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
CUBS	: Carotid Ultrasound Boundary Study
DL	: Deep Learning (Derin Öğrenme)
DSC	: Dice Similarity Coefficient (Dice Benzerlik Katsayısı)
ECA	: External Carotid Artery (Dış Karotid Arter)
ECST	: European Carotid Surgery Trial
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Pozitif)
GSC	: Gated Spatial Convolution
ICA	: Internal Carotid Artery (İç Karotid Arter)
IMT	: Intima-Media Thickness (İntima-Media Kalınlığı)
IoU	: Intersection over Union (Kesişim Bölgesi Oranı)
LI	: Lumen-Intima (Lümen-İntima Sınırı)
MA	: Media-Adventisya Sınırı
MIP	: Maksimum İntensite Projeksiyonu
MR	: Manyetik Rezonans
MRA	: Manyetik Rezonans Anjiyografi
NASCET	: North American Symptomatic Carotid Endarterectomy Trial
PA	: Pixel Accuracy (Piksel Doğruluğu)
SSM	: State Space Model (Durum Uzayı Modeli)
TIA	: Transient Ischemic Attack (Geçici İskemik Atak)
TN	: True Negative (Doğru Negatif)
TOF	: Time-of-Flight
ToM	: Tri-orientated Mamba,
TP	: True Positive (Doğru Pozitif)

US	: Ultrasonografi
VM-UNet	: Vision Mamba UNet
VR	: Volume Rendering (Hacim Görüntüleme)
WHO	: World Health Organization (Dünya Sağlık Örgütü)



ŞEKİLLER DİZİNİ

Şekil No	Sayfa No
Şekil 1.1. Tez çalışmasının grafiksel özeti	5
Şekil 2.1. UNet mimarisi	9
Şekil 2.2. SegNet mimarisi diagramı	10
Şekil 2.3. DeepLab v3+ mimarisinin diagramı	11
Şekil 2.4. Mask R-CNN algoritmasının diagramı	12
Şekil 2.5. Attention UNet mimarisi	13
Şekil 2.6. UNet ++ mimarisi	14
Şekil 2.7. TransUNet algoritmasına ait mimari model	15
Şekil 2.8. Swin-Unet algoritması blok diagramı	16
Şekil 2.9. Visual Mamba UNet mimarisi	17
Şekil 2.10. Karodit arter hastalığı	20
Şekil 3.1. Dice benzerlik katsayısı eşitliği	25
Şekil 3.2. Kesişim bölgesi oranı eşitliği	25
Şekil 3.3. Hassasiyet metriği eşitliği	26
Şekil 3.4. Özgüllük metriği eşitliği	26
Şekil 3.5. Doğruluk metriği eşitliği	27
Şekil 3.6. Kesinlik metriği eşitliği	27
Şekil 3.7. PA değeri eşitliği	28
Şekil 3.8. F1 skoru eşitliği	28
Şekil 3.9. Meme ultrason imgesi lezyon bölütleme ve sınıflandırma yazılımı	32
Şekil 3.10. Karotid arter bölütleme yazılımı	37
Şekil 4.1. CCA Veri seti bölütleme metrik değerleri	38
Şekil 4.2. Vision Mamba UNet algoritması karotid arter bölütleme çıktısı	38
Şekil 4.3. BUSI veri seti bölütleme performans metrikleri	39
Şekil 4.4. BUSI veri setinin bölütleme çıktıları	40
Şekil 4.5. BUSI veri setinin sınıflandırma metrik değerlerinin grafiksel gösterimi	41

TABLÖLAR DİZİNİ

Tablo No	Sayfa No
Tablo 4.1. CCA veri setinde bölütleme algoritmalarının karşılaştırması.....	37
Tablo 4.2. BUSI veri setinde bölütleme algoritmalarının karşılaştırması.....	39
Tablo 4.3. BUSI veri setinde sınıflandırma algoritmalarının karşılaştırması	40



1. GİRİŞ

Günümüzde tıbbi görüntüleme teknolojilerindeki ilerlemeler, hastalıkların tanısında, tedavi planlamasında ve takibinde büyük kolaylıklar sağlamaktadır. Röntgen, bilgisayarlı tomografi (BT), manyetik rezonans görüntüleme (MR), ultrasonografi (US) gibi farklı modalitelerden elde edilen tıbbi görüntüler, klinik uygulamalarda önemli bilgi kaynakları haline gelmiştir. Ancak, bu görüntülerin sayısının ve karmaşıklığının artması, radyologların iş yükünü artırmakta ve değerlendirme süreçlerinde zaman baskısı oluşturmaktadır. Bu durum, görüntü analizinde insan faktörüne bağlı yorgunluk, dikkat dağınıklığı ve subjektif değerlendirme gibi faktörlerin etkisiyle tanısal hatalara yol açabilmektedir (1).

Tıbbi görüntüleme, hastalıkların teşhisi ve yönetiminde kritik bir rol oynamaktadır. Son otuz yılda, tıbbi görüntüleme cihazlarının teknolojik gelişimi, daha yüksek çözünürlüklü, daha hassas ve daha hızlı görüntülerin elde edilmesini sağlamıştır. Bu gelişmeler sayesinde, daha önce keşfedilemeyen anatomik detaylar ve patolojik değişiklikler görünür hale gelmiştir. Ancak, görüntü kalitesindeki bu iyileşmeye rağmen, artan hasta sayısı ve karmaşık vakaların çoğalması nedeniyle, radyoloji pratiğinde verimlilik ve tutarlılık zorlukları ortaya çıkmıştır. Günde yüzlerce görüntüyü değerlendirmek zorunda kalan radyologlar, yorgunluk ve zaman baskısı altında bazen kritik bulguları gözden kaçırabilmektedir (2).

Son yıllarda yapay zekâ (AI) ve derin öğrenme (DL) teknolojilerindeki gelişmeler, tıbbi görüntü işleme ve analizi alanında devrim niteliğinde ilerlemeler sağlamıştır. Özellikle derin öğrenme tabanlı algoritmalar, karmaşık görüntü özelliklerini otomatik olarak öğrenebilme ve bu özellikleri kullanarak yüksek doğrulukta bölütleme ve sınıflandırma yapabilme yetenekleri ile ön plana çıkmaktadır (3). Bu algoritmalar, radyologların iş yükünü azaltma, tanısal doğruluğu artırma ve hasta bakım kalitesini iyileştirme potansiyeline sahiptir.

Derin öğrenme, yapay sinir ağlarının çok katmanlı bir formu olup, karmaşık ve yüksek boyutlu verilerde örüntü tanıma yeteneğiyle dikkat çekmektedir. Geleneksel makine öğrenmesi yaklaşımlarından farklı olarak, derin öğrenme algoritmaları ham verilerden otomatik olarak özellik çıkarabilmekte ve bu özellikleri kullanarak karmaşık görevleri gerçekleştirebilmektedir. Bu özellik, özellikle tıbbi görüntüleme gibi yüksek boyutlu ve karmaşık veri setleri için büyük avantaj sağlamaktadır (4).

Derin öğrenme teknolojilerinin tıbbi görüntü analizinde başarılı bir şekilde uygulanması, büyük ölçüde evrimsel sinir ağları (CNN) ve bunların geliştirilmiş sürümleri sayesinde mümkün olmuştur. CNN, görüntü verileri üzerinde uzamsal ilişkileri yakalayabilen ve hiyerarşik özellik öğrenimini sağlayan özel bir yapay sinir ağı türüdür. Bu ağlar, düşük seviyeli kenar ve doku özelliklerinden yüksek seviyeli yapısal ve bağlamsal özelliklere kadar görüntülerdeki çeşitli bilgileri öğrenebilme yeteneğine sahiptir (5).

Tıbbi görüntü bölütleme (segmentasyon), tıbbi görüntülerdeki farklı doku ve organların otomatik olarak tespit edilmesi ve ayrıştırılması işlemidir. Bu süreç, tıbbi tanı, tedavi planlaması ve hastalık takibi için kritik öneme sahiptir. Geleneksel bölütleme yöntemleri genellikle manuel veya yarı otomatik olup, zaman alıcı ve operatöre bağımlıdır. Derin öğrenme tabanlı bölütleme algoritmaları ise, insan müdahalesine minimal ihtiyaç duyan, hızlı ve tekrarlanabilir sonuçlar sunmaktadır (6).

Son yıllarda, U-Net mimarisi ve onun türevleri (SegNet, DeepLab v3, Mask R-CNN, Attention U-Net, U-Net++, TransUNet, Swin UNet ve Vision Mamba UNet gibi), tıbbi görüntü bölütleme görevlerinde yaygın olarak kullanılmaktadır. Bu mimariler, kodlayıcı-kod çözücü yapısına sahip olup, görüntüdeki hem yerel hem de küresel bağlamsal bilgileri etkili bir şekilde yakalayabilmektedir. Özellikle, atlamalı bağlantılar (skip connections) sayesinde, kodlayıcı aşamasındaki düşük seviyeli özellikler, kod çözücü aşamasına doğrudan aktarılabilmekte ve bu sayede bölütleme performansı artırılabilir (7).

Kardiyovasküler hastalıklar, dünya genelinde önde gelen ölüm nedenlerinden biridir ve karotid arter hastalıkları, özellikle inme riski ile yakından ilişkilidir (8). Dünya Sağlık Örgütü'nün (WHO) raporlarına göre, kardiyovasküler hastalıklar her yıl yaklaşık 17.9 milyon insanın hayatını kaybetmesine neden olmaktadır ve bu ölümlerin yaklaşık üçte biri inme kaynaklıdır. İnme vakalarının önemli bir kısmı, karotid arter hastalıklarından kaynaklanmaktadır. Bu nedenle, karotid arter patolojilerinin erken ve doğru teşhisi, inmelerin önlenmesi ve toplum sağlığının korunması açısından büyük önem taşımaktadır (9).

Karotid arterlerde aterosklerotik plak varlığı ve stenoz derecesi, inme riskinin önemli belirleyicileri olarak kabul edilmektedir. Aterosklerotik plaklar, arterlerin iç duvarında lipit, kalsiyum, kollajen ve diğer hücresel bileşenlerin birikmesiyle oluşur

ve zamanla arter lümeninde daralmaya (stenoz) yol açabilir. Yüksek dereceli stenozlar, kan akışını önemli ölçüde kısıtlayarak serebral iskemiye ve inmeye neden olabilir. Ayrıca, plak morfolojisi ve kompozisyonu da inme riski üzerinde etkilidir; özellikle, ülsere, hemorajik veya lipidden zengin plaklar daha yüksek embolik potansiyele sahiptir (10).

Meme kanseri, günümüzde kadınları etkileyen en yaygın kanser türü olarak küresel halk sağlığının en ciddi sorunlarından birini oluşturmaktadır. Dünya genelinde yılda yaklaşık 2.3 milyon yeni meme kanseri vakası tespit edilmekte ve 670.000 ölüm gerçekleşmektedir (11). Meme kanserinde erken tanı ve müdahale, hasta yaşam kalitesi ve sağkalım oranları açısından kritik öneme sahiptir. Mammografi, erken evre meme kanserini tespit etmek için günümüzde en başarılı araç olarak kabul edilmekte ve tedavinin en etkili olacağı dönemde tanı konulmasını sağlamaktadır (12).

Son yıllarda yapay zekâ ve derin öğrenme teknolojilerinin meme kanseri görüntüleme analizindeki uygulamaları, tanı doğruluğunu artırma ve iş akışlarını optimize etme konusunda önemli ilerlemeler kaydetmiştir (13). Bilgisayar destekli tanı (CAD) sistemleri, radyologlara "ikinci bir göz" işlevi görerek meme kanseri tespitinde doğruluğu artırmaktadır (14).

Karotid arter hastalıklarının değerlendirilmesinde, ultrasonografi (US), bilgisayarlı tomografi anjiyografi (BTA) ve manyetik rezonans anjiyografi (MRA) gibi farklı görüntüleme modaliteleri kullanılmaktadır. Ultrasonografi, non-invaziv, radyasyon içermeyen, uygun maliyetli bir yöntem olması nedeniyle genellikle ilk tercih edilen görüntüleme yöntemidir. BTA ve MRA ise daha detaylı anatomik bilgi sağlamakta, ancak daha yüksek maliyet ve (BTA durumunda) radyasyon maruziyeti gibi dezavantajlara sahip olabilmektedir. Her bir modalite kendine özgü avantajlara sahip olmakla birlikte, görüntülerin manuel değerlendirmesi zaman alıcı olabilmekte ve değerlendirmeler arası tutarlılık farklılıkları gösterebilmektedir (15).

Bu noktada, derin öğrenme tabanlı görüntü analizi algoritmaları, karotid arter görüntülemesinde önemli bir role sahip olabilir. Bu algoritmalar, karotid arterlerin otomatik bölütlenmesi, plak karakterizasyonu ve stenoz derecesinin belirlenmesi gibi görevlerde kullanılabilir. Derin öğrenme modellerinin, radyologların iş yükünü azaltma, tanısal tutarlılığı artırma ve erken tanı olanaklarını geliştirme potansiyeli bulunmaktadır (16).

Literatürde, tıbbi görüntü analizi için çeşitli derin öğrenme mimarileri önerilmiştir. U-Net mimarisi (17), tıbbi görüntü bölütleme için özel olarak tasarlanmış olup, kodlayıcı-kod çözücü yapısı ve atlamalı bağlantıları sayesinde yüksek çözünürlüklü bölütleme sonuçları elde edilmesini sağlamaktadır. SegNet (18), benzer bir yapıya sahip olmakla birlikte, maksimum havuzlama indekslerini kullanarak daha hassas sınır lokalizasyonu sağlamaktadır. DeepLab v3 (19), atrous (dilated) konvolüsyonları ve atrous uzamsal piramit havuzlama (ASPP) modülünü kullanarak, çok ölçekli özellik çıkarma yeteneğine sahiptir. Mask R-CNN (20), nesne tespiti ve bölütleme görevlerini birleştiren bir yaklaşım sunmaktadır. Attention U-Net (21), ilgi alanlarına odaklanan dikkat mekanizmaları içermektedir. U-Net++ (22), U-Net'in daha derin ve daha yoğun bağlantılı bir sürümüdür. TransUNet (23), transformatörlerin küresel bağlam yakalama yeteneğini CNN'lerin yerel bilgi işleme yeteneğiyle birleştirmektedir. Swin U-Net (24) , Swin Transformer ile U-Net'in avantajlarını birleştirerek hem yerel hem de küresel özellikleri etkili şekilde yakalar. Son olarak, Vision Mamba UNet (25), Durum Uzayı Modellerini (SSM) kullanarak uzun menzilli bağımlılıkları yakalama yeteneğine sahiptir.

Derin öğrenme algoritmalarının başarısı, büyük ölçüde eğitim verilerinin kalitesine ve miktarına bağlıdır. Tıbbi görüntüleme alanında, yüksek kaliteli ve etiketli veri elde etmek zor olabilmektedir. Bu zorluk, veri artırma (data augmentation), transfer öğrenme (transfer learning) ve az sayıda örnekle öğrenme (few-shot learning) gibi tekniklerle aşılmaya çalışılmaktadır. Ayrıca, tıbbi görüntülerde genellikle gözlenen sınıf dengesizliği problemi (örneğin, normal doku piksellerinin patolojik doku piksellerine göre çok daha fazla olması), ağırlıklı kayıp fonksiyonları ve örneklem dengeleme teknikleri ile ele alınmaktadır (26).


Derin öğrenme modellerinin klinik uygulamalarda başarılı bir şekilde kullanılabilmesi için, sadece yüksek performans değil, aynı zamanda güvenilirlik, yorumlanabilirlik ve genellenebilirlik gibi faktörler de önemlidir. Modelin hangi özelliklere dayanarak karar verdiğini anlamak, klinik güveni artırmak açısından kritiktir. Ayrıca, modelin farklı hasta popülasyonları, görüntüleme protokolleri ve cihazları üzerinde tutarlı performans gösterebilmesi, gerçek dünya uygulamaları için gereklidir (27).

Bu tez çalışmasının amacı, radyolojik görüntülerde derin öğrenme yaklaşımlarıyla bölütleme ve sınıflandırma konusunu ele almak ve meme lezyonlarını ve karotid arterin teşhisinde derin öğrenme tabanlı görüntü bölütleme ve sınıflandırma yöntemlerinin

etkinliğini kapsamlı bir şekilde değerlendirmektir. Çalışmada, radyolojik görüntüleme modalitelerinden ultrasonografi ile elde edilen görüntüler üzerinde çeşitli derin öğrenme mimarilerinin performansları karşılaştırılmış ve klinik kullanım için en uygun algoritmaların belirlenmesi hedeflenmiştir. Özellikle, UNet, SegNet, DeepLab v3+, Mask R-CNN, Attention UNet, UNet++, TransUNet, Swin UNet ve Vision Mamba UNet gibi son teknoloji derin öğrenme mimarilerinin karotid arter bölütleme ve Meme lezyonu bölütleme ve sınıflandırma performansları detaylı bir şekilde incelenmiş ve karşılaştırılmıştır.

Çalışmada ayrıca, geliştirilen modellerin klinik iş akışına entegrasyonu, radyologlara karar destek mekanizması olarak nasıl kullanılabileceği ve potansiyel faydaları da tartışılmıştır. Derin öğrenme tabanlı sistemlerin klinik kullanımının önündeki teknik, etik ve düzenleyici engeller ele alınmış ve bu engellerin aşılmasına yönelik öneriler sunulmuştur.

Bu tez çalışması kapsamında, karotid arter bölütlemesi için halka açık Common Carotid Artery Ultrasound Images Dataset (CCA) (28) isimli veri seti kullanılmıştır. Meme lezyonlarını bulmak ve sınıflandırmak için ise yine halka açık Breast Ultrasound Images Dataset (BUSI) (29) isimli veri seti kullanılmıştır. Görüntüler, uygun ön işleme tekniklerinden geçirildikten sonra, çeşitli veri artırma teknikleri kullanılarak eğitim veri seti genişletilmiştir. Farklı derin öğrenme mimarileri, bu veri seti üzerinde eğitilmiş ve performansları DSC, IoU, Kesinlik, Duyarlılık, F1 skor gibi metrikler kullanılarak değerlendirilmiştir. Tez çalışmasının grafiksel özeti Şekil 1.1.'de sunuldu.



Şekil 1.1. Tez çalışmasının grafiksel özeti

Tez çalışmasının, literatüre özgün katkıları şu şekilde özetlenebilir:

- Ultrason modalitelerden elde edilen karotid arter ve meme görüntülerinde derin öğrenme mimarilerinin performansının kapsamlı bir şekilde değerlendirilmesi,
- Karotid arter bölütleme ve meme lezyonu bölütleme ve sınıflandırma görevleri için yüksek performanslı derin öğrenme mimarilerinin belirlenmesi,
- Derin öğrenme modellerinin performansını etkileyen faktörlerin (veri miktarı, veri kalitesi, model kompleksitesi vb.) sistematik olarak analiz edilmesi,
- Geliştirilen uygulamaların klinik kullanımına yönelik pratik önerilerin sunulması,
- Derin öğrenme tabanlı sistemlerin radyolojik tanı süreçlerine entegrasyonu için bir çerçeve oluşturulması.

Bu tez çalışmasının sonuçlarının, radyolojik görüntü analizi alanında derin öğrenme teknolojilerinin etkin kullanımına katkıda bulunacağı ve karotid arter hastalıklarının ve meme kanserinin tanı ve yönetiminde yeni yaklaşımlar sunacağı düşünülmektedir. Ayrıca, çalışmada elde edilen bulgular ve geliştirilen metodolojiler, diğer vasküler patolojilerin değerlendirilmesinde de uygulanabilir nitelikte olup, kardiyovasküler görüntüleme ve meme lezyonu tespiti ve sınıflandırılması alanında derin öğrenme uygulamalarına rehberlik edebilecektir.

2. GENEL BİLGİLER

Radyolojik görüntüleme teknikleri ve yapay zekâ teknolojilerindeki ilerlemeler, tıbbi tanı ve tedavi yöntemlerinde ciddi gelişmelere yol açmıştır. Bu bölümde, tez konusunun temelini oluşturan radyolojik görüntüleme modaliteleri ve bu modalitelerin karotid arter hastalığında ve meme lezyonu bölütleme ve sınıflandırma konusunda kullanımı; derin öğrenme yaklaşımları ve literatürde derin öğrenme yaklaşımlarıyla gerçekleştirilmiş karotid arter bölütleme ve meme lezyonu bölütleme ve sınıflandırma çalışmaları hakkında detaylı bilgiler sunulacaktır.

2.1. Radyolojik Görüntüleme Modaliteleri

Radyolojik görüntüleme, hastalıkların teşhisinde ve takibinde kullanılan en önemli yöntemlerden biridir. Farklı fiziksel prensiplere dayanan bu modaliteler, vücudun içyapılarının görselleştirilmesini sağlayarak hekimlere tanı koymada önemli bilgiler sunar. Bu bölümde, çalışmamızda kullanılan temel görüntüleme yöntemleri olan ultrason, MR ve BT teknikleri detaylı olarak ele alınacaktır.

2.1.1. Ultrason

Ultrason görüntüleme, yüksek frekanslı ses dalgalarının vücut dokularında yayılması ve bu dokulardan geri yansımaları prensibine dayanır. Ultrason dalgaları bir transdüser vasıtasıyla vücuda gönderilir ve dokulardan yansıyan ekolar kaydedilerek görüntüye dönüştürülür. Bu teknik, iyonize radyasyon kullanmadığı, taşınabilir olduğu ve gerçek zamanlı görüntüleme sağladığı için klinik uygulamalarda yaygın olarak tercih edilmektedir (30).

Ultrason, vasküler yapıların değerlendirilmesinde özellikle değerlidir. (31). Karotid ultrasonu, karotid arter hastalıklarının değerlendirilmesinde ilk tercih edilen görüntüleme yöntemidir (32) Ultrason görüntüleme, vasküler yapıların değerlendirilmesinde önemli avantajlara sahip olmasına rağmen, bazı kısıtlamaları da bulunmaktadır(33).

Kontrast madde destekli ultrason (CEUS), üç boyutlu ultrason (3D ultrason) ve elastografi gibi ileri ultrason teknikleri, vasküler yapıların daha detaylı değerlendirilmesine imkan vermektedir (35). Buna rağmen ultrason görüntüleme klinikte sıklıkla kullanılmaktadır.

2.1.2. Manyetik Rezonans Görüntüleme (MR)

Manyetik Rezonans Görüntüleme (MR), güçlü bir manyetik alan içinde vücuttaki hidrojen atomlarının rezonansa getirilmesi ve bu rezonans sonrası yayılan sinyallerin işlenmesi prensibine dayanır (36). MR, yumuşak doku kontrastı sağlamada üstün performans göstermesi, iyonize radyasyon kullanmaması ve multiplanar görüntüleme yeteneği ile klinik uygulamalarda sıklıkla tercih edilmektedir (37).

2.1.3. Bilgisayarlı Tomografi (BT)

Bilgisayarlı Tomografi (BT), X-ışınlarının vücuda farklı açılardan gönderilmesi ve detektörler tarafından kaydedilmesi sonucu elde edilen kesitsel görüntüleme yöntemidir. (38).

2.2. Derin Öğrenme Yaklaşımı ile Görüntü Bölütleme

Derin öğrenme, son yıllarda tıbbi görüntü analizi alanında devrim niteliğinde gelişmelere yol açmıştır. Özellikle görüntü bölütleme (segmentasyon) gibi karmaşık görevlerde, geleneksel yöntemlere kıyasla üstün performans göstermektedir. Tıbbi görüntülerde organ, lezyon veya damar gibi anatomik yapıların otomatik olarak bölütlenmesi, bilgisayar destekli tanı sistemlerinin temel bileşenlerinden biridir (39).

Görüntü bölütleme, bir görüntüyü semantik olarak anlamlı bölgelere ayırma işlemidir. Tıbbi görüntülemede bölütleme, belirli doku veya organların otomatik olarak tanımlanması, sınırlarının belirlenmesi ve diğer dokulardan ayrılması anlamına gelir. Bu işlem, manuel olarak yapıldığında zaman alıcı ve subjektif olabilmektedir. Derin öğrenme tabanlı otomatik bölütleme yöntemleri, bu süreci hızlandırarak daha objektif ve tekrarlanabilir sonuçlar elde edilmesini sağlamaktadır (40).

Derin öğrenme tabanlı bölütleme yaklaşımları, özellikle CNN ve onların türevleri üzerine kurulmuştur. Bu yaklaşımlar, görüntülerden otomatik olarak özellik çıkarabilme ve bu özellikleri kullanarak piksel seviyesinde sınıflandırma yapabilme yetenekleri ile ön plana çıkmaktadır. Geleneksel makine öğrenmesi yöntemlerinden farklı olarak, derin öğrenme modelleri ham görüntü verilerinden yüksek seviyeli temsilciler oluşturabilmekte ve bu sayede daha karmaşık desenleri tanıyabilmektedir (41).

Tıbbi görüntülerin bölütlenmesinde karşılaşılan başlıca zorluklar arasında, görüntü kontrastı düşüklüğü, görüntü gürültüsü, doku heterojenitesi ve anatomik yapıların değişkenliği yer almaktadır. Derin öğrenme mimarileri, bu zorluklarla başa


çıkabilmek için farklı tasarım yaklaşımları benimsemişlerdir. Özellikle U-Net ve türevleri, tıbbi görüntü bölütleme problemlerinde yüksek başarı göstermektedir (42).

2.2.1. U-Net

U-Net, biyomedikal görüntü bölütleme için özel olarak tasarlanmış bir evrişimsel sinir ağı mimarisidir. İlk olarak 2015 yılında Ronneberger ve ark. (17) tarafından önerilen bu mimari, U şeklindeki yapısı nedeniyle bu ismi almıştır. U-Net, kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki ana bileşenden oluşmaktadır.

Kodlayıcı kısmı, geleneksel CNN mimarilerine benzer şekilde, evrişim (convolution) ve havuzlama (pooling) katmanlarının ardışık diziliminden oluşur. Bu katmanlar, görüntüden düşük seviyeli özellikleri (kenarlar, dokular vb.) çıkarırken, uzamsal boyutları kademeli olarak azaltır. Kod çözücü kısım ise, yukarı örnekleme (upsampling) ve evrişim işlemleri ile uzamsal boyutları tekrar artırarak, özellik haritalarını orijinal görüntü boyutlarına getirir (17).

U-Net'in en önemli özelliklerinden biri, kodlayıcı ve kod çözücü arasındaki atlamalı bağlantılardır (skip connections). Bu bağlantılar, kodlayıcı kısmında elde edilen detaylı uzamsal bilgilerin, kod çözücü kısmına doğrudan aktarılmasını sağlar. Bu sayede, havuzlama işlemleri sırasında kaybolan uzamsal bilgiler korunmuş olur ve daha hassas sınır lokalizasyonları elde edilebilir (43). UNet mimarisi Şekil 2.1.'de gösterildi.



Şekil 2.1. UNet mimarisi

U-Net, özellikle sınırlı eğitim verisi durumlarında etkili performans göstermektedir. Bu özelliği, onu tıbbi görüntü bölütleme alanında popüler hale getirmiştir. Paranthaman ve arkadaşlarının (44) yaptığı bir çalışmada, U-Net mimarisinin karotid arter segmentasyonunda yüksek başarı gösterdiği ve manuel segmentasyonla yüksek derecede uyumlu sonuçlar ürettiği bildirilmiştir.

U-Net mimarisi, tıbbi görüntü bölütleme alanında referans nokta haline gelmiş ve birçok modifikasyona temel oluşturmuştur. 3D U-Net, Recurrent U-Net, Attention U-Net ve U-Net++ gibi türevler, U-Net'in farklı görevlere adaptasyonu ve performansının artırılması amacıyla geliştirilmiştir (45).

2.2.2. SegNet

SegNet, 2015 yılında Badrinarayanan ve ark. (18) tarafından önerilen, görüntü bölütleme için tasarlanmış bir derin öğrenme mimarisidir. SegNet, otomatik sürüş sistemleri için sahne anlama uygulamaları odaklı geliştirilmiş olsa da, tıbbi görüntü analizi dâhil birçok alanda başarıyla uygulanmıştır.

SegNet mimarisi, U-Net'e benzer şekilde kodlayıcı-kod çözücü yapısına sahiptir. Ancak, U-Net'ten farklı olarak, SegNet'in kod çözücü kısmında yukarı örnekleme işlemi için maksimum havuzlama indekslerinin kullanması önemli bir farklılıktır. Kodlayıcı kısmındaki her maksimum havuzlama katmanında, en yüksek değere sahip piksellerin konumları kaydedilir ve bu indeksler, kod çözücü kısmında yukarı örnekleme işlemi sırasında kullanılır. Bu yaklaşım, sınır bilgilerinin daha iyi korunmasını sağlayarak, özellikle hassas sınır lokalizasyonu gerektiren uygulamalarda avantaj sağlamaktadır (18). Şekil 2.2.'de SegNet mimarisi diagramı verildi.




Şekil 2.2. SegNet mimarisi diagramı

2.2.3. DeepLab v3+

DeepLab serisi, Chen ve arkadaşları (46) tarafından geliştirilen ve görüntü bölütleme problemleri için tasarlanmış derin öğrenme mimarilerini içermektedir. DeepLab v3+, serinin en gelişmiş sürümüdür ve 2018 yılında önerilmiştir. Bu mimari, Atrous Spatial Pyramid Pooling (ASPP) modülü ve kodlayıcı-kod çözücü yapısını birleştirerek, hem çoklu ölçeklerdeki bilgileri yakalama hem de hassas sınır lokalizasyonu sağlama yeteneklerine sahiptir.

DeepLab mimarisinin en önemli bileşenlerinden biri, atrous (dilated) konvolüsyonlardır. Atrous konvolüsyonlar, standart konvolüsyonlara göre daha geniş reseptif alanlar sağlar ve böylece daha büyük bağlamsal bilgilerin yakalanmasına olanak tanır. ASPP modülü ise, farklı atrous oranlarına sahip konvolüsyonları paralel olarak uygulayarak, çoklu ölçeklerdeki özelliklerin etkili bir şekilde yakalanmasını sağlar (46). DeepLab v3+ mimarisinin diagramı Şekil 2.3.'de gösterildi.



Şekil 2.3. DeepLab v3+ mimarisinin diagramı


DeepLab v3+, kodlayıcı kısmında backbone olarak farklı ağları (ResNet, Xception, MobileNet vb.) kullanabilme esnekliğine sahiptir. Bu özellik, farklı uygulama gereksinimlerine göre mimariyi uyarlama imkânı sağlar. Örneğin, yüksek doğruluk gerektiren uygulamalarda Xception backbone, hafif ve hızlı uygulamalarda ise MobileNet backbone tercih edilebilir.

2.2.4. Mask R-CNN

Mask R-CNN, 2017 yılında He ve ark. (47) tarafından geliştirilen, nesne tespiti ve bölütleme görevlerini birleştiren güçlü bir derin öğrenme mimarisidir. Faster R-CNN

nesne tespit modelinin bir uzantısı olan Mask R-CNN, tespit edilen her nesne için bir bölütleme maskesi de üretir.

Mask R-CNN, iki aşamalı bir işlem uygular: İlk aşamada, görüntüdeki potansiyel nesne adayları (Region Proposals) belirlenir. İkinci aşamada, bu adaylar sınıflandırılır, sınırlayıcı kutuları (bounding boxes) iyileştirilir ve her bir nesne için piksel seviyesinde bir bölütleme maskesi üretilir. Mimarinin en önemli yeniliklerinden biri, RoIAlign katmanıdır. Bu katman, özellik haritalarından sabit boyutlu özniteliklerin çıkarılması sırasında uzamsal bilgilerin korunmasını sağlayarak, daha hassas bölütleme sonuçları elde edilmesine olanak tanır (47). Şekil 2.4.'de Mask R-CNN algoritmasının diagramı gösterildi.




Şekil 2.4. Mask R-CNN algoritmasının diagramı

2.2.5. Attention U-Net

Attention U-Net, Oktay ve ark. (21) tarafından 2018 yılında önerilen, U-Net mimarisine dikkat (attention) mekanizması eklenmiş bir derin öğrenme modelidir. Dikkat mekanizmaları, modelin görüntüdeki belirli bölgelere daha fazla "dikkat" etmesini sağlayarak, ilgili yapıların daha doğru bölütlenmesini amaçlar.

Attention U-Net, standart U-Net mimarisine eklenen Attention Gate (AG) modülleri ile karakterizedir. Bu modüller, kodlayıcı kısmından gelen özellik haritaları ve kod çözücü kısmındaki yukarı örneklenmiş özellik haritaları arasında bir dikkat katsayısı

hesaplar. Bu katsayılar, özellik haritalarının ilgili bölgelere daha fazla ağırlık verecek şekilde ölçeklendirilmesini sağlar. Böylece, hedef yapının bulunduğu bölgeler vurgulanırken, arka plan veya ilgisiz bölgeler bastırılır (21). Şekil 2.5.'de Attention UNet algoritması mimarisi gösterildi.




Şekil 2.5. Attention UNet mimarisi

2.2.6. U-Net++

U-Net++, Zongwei ve ark. (22) tarafından 2018 yılında önerilen, U-Net mimarisinin yoğun bağlantılı bir sürümüdür. U-Net++'nin temel amacı, kodlayıcı ve kod çözücü arasındaki semantik boşluğu azaltarak bölütleme performansını artırmaktır.

U-Net++ mimarisinin bir diğer önemli özelliği, derin gözetim (deep supervision) mekanizmasıdır. Bu mekanizma, farklı ölçeklerdeki kod çözücü çıktılarının her birinden bağımsız tahminler yapılmasını sağlar ve model eğitimi sırasında bu tahminlerin her biri için kayıp hesaplanır. Bu yaklaşım, gradyan akışını iyileştirir ve modelin daha hızlı ve kararlı bir şekilde öğrenmesine katkıda bulunur. Şekil 2.6.'da U-Net++ algoritmasının mimarisi gösterildi.

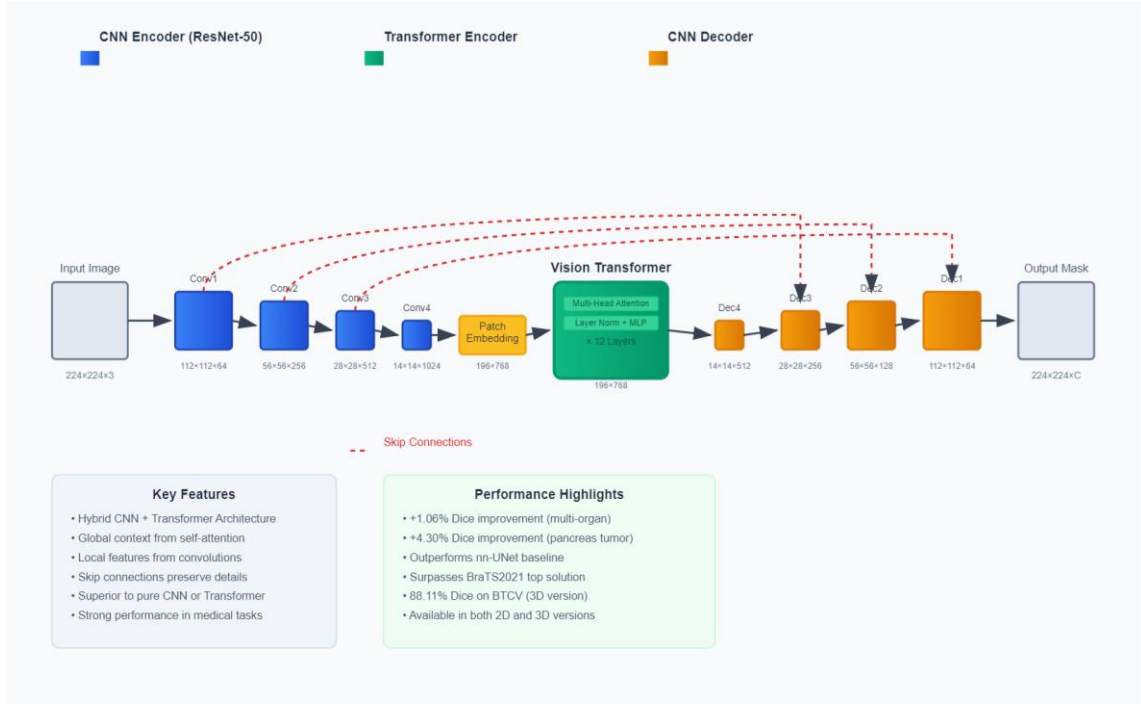


Şekil 2.6. UNet ++ mimarisi

2.2.7. TransUNet

TransUNet, konvolüsyonel U-Net yapısını Vision Transformer (ViT) ile birleştiren hibrit bir mimaridir. Chen ve ark. (23), CNN tabanlı özellik haritalarını küçük patch'lere bölüp Transformer encoder'a besleyerek uzun menzilli bağlam bilgisini yakalamayı; ardından U-Net benzeri decoder'da yüksek çözünürlüklü CNN özellikleriyle birleştirerek keskin sınırları geri kazanmayı önermiştir. Bu sayede, çoklu-organ ve kardiyak segmentasyon gibi görevlerde saf CNN temelli yöntemlere kıyasla daha üstün sonuçlar elde edilmiştir.

TransUNet; hem yerel (local) hem de küresel (global) bağlamı yakalamadaki başarısıyla Transformer-tabanlı segmentasyon mimarilerinin öncüsü olarak tanımlanmıştır. Şekil 2.7.'de TransUNet R2U-Net algoritmasına ait mimari model gösterildi.



Şekil 2.7. TransUNet algoritmasına ait mimari model

2.2.8. Swin- Unet

Cao ve ark. (24) tarafından geliştirilen Swin-Unet, tıbbi görüntü segmentasyonu için tamamen Transformer tabanlı bir U-Net benzeri mimarisidir. Geleneksel CNN'lerin evrişim işleminin yerelliği nedeniyle küresel ve uzun mesafeli semantik bilgi etkileşimini iyi öğrenememesi problemini ele almak için tasarlanmıştır. Bu yaklaşımda, tokenize edilmiş görüntü yamaları, yerel-küresel semantik özellik öğrenimi için atlama bağlantıları olan Transformer tabanlı U şeklindeki Encoder-Decoder mimarisine beslenir. Swin-Unet, CNN tabanlı geleneksel U-Net mimarisinin yerini tamamen Transformer bileşenleriyle alır.

Algoritmanın mimarisi, bağlam özelliklerini çıkarmak için hiyerarşik Swin Transformer ile kaydırılmış pencereler kullanan bir encoder ve özellik haritalarının uzamsal çözünürlüğünü geri yüklemek için patch expanding katmanı içeren simetrik Swin Transformer tabanlı bir decoder'dan oluşmaktadır. 4x direkt down-sampling ve up-sampling ile çalışan model, çok-organ ve kardiyak segmentasyon görevlerinde yapılan deneylerde, tam konvolüsyonel yöntemlerden veya transformer-konvolüsyon hibrit yaklaşımlarından daha üstün performans sergilemiştir. Swin Transformer'ın pencere tabanlı dikkat mekanizması sayesinde hem hesaplama verimliliği sağlanmış hem de

küresel bağlamsal bilgi etkili şekilde yakalanmıştır. Swin-Unet blok diagramı Şekil 2.8.'de gösterildi.




Şekil 2.8. Swin-Unet algoritması blok diagramı

2.2.9. Vision Mamba UNet

Vision Mamba UNet, son dönemde geliştirilen ve Durum Uzaı Modelleri (state space models - SSM) ile CNN'leri birleştiren yenilikçi bir derin öğrenme mimarisidir. Mamba, Ruan ve ark. (25) tarafından önerilen ve verimli bir şekilde uzun menzilli bağımlılıkları modelleyebilen bir SSM mimarisidir. Transformatörlere alternatif olarak geliştirilmiş olan Mamba, daha az hesaplama maliyeti ile benzer veya daha iyi performans gösterebilmektedir.

Vision Mamba UNet, U-Net'in kodlayıcı-kod çözücü yapısını korurken, standart konvolüsyon bloklarının yerini Mamba blokları alır. Bu bloklar, görsel verilerdeki uzun menzilli bağımlılıkları modelleyerek, küresel bağlamsal bilgilerin daha etkili bir şekilde yakalanmasını sağlar. Ayrıca, Mamba blokları, görüntünün 2D yapısını korumak için özel olarak tasarlanmış mekanizmalar içerir. Şekil 2.9.'da Vision Mamba UNet mimarisi gösterilmiştir.



Şekil 2.9. Visual Mamba UNet mimarisi

Mamba mimarilerinin tıbbi görüntü analizi alanındaki uygulamaları henüz yeni olmakla birlikte, ilk sonuçlar umut vericidir. Özellikle, hesaplama verimliliği ve uzun menzilli bağımlılıkları modelleyebilme yeteneği, Vision Mamba Unet'i klinik uygulamalar için potansiyel bir aday haline getirmektedir (48).

2.3. Derin Öğrenme Algoritmaları ile Görüntü Sınıflandırma

2.3.1. CNN Modelleri ile Sınıflandırma

Evrşimsel sinir ağları (CNN), görüntü sınıflandırma problemlerinde son yıllarda çığır açan başarılar elde etmiştir. Krizhevsky ve ark. (2012) tarafından önerilen AlexNet (49), 1.2 milyon yüksek çözünürlüklü görüntüyü sınıflandırmış ve ImageNet LSVRC-2010 yarışmasında top-5 hata oranını %17.0'a düşürerek derin konvolüsyonel ağların potansiyelini göstermiştir. Simonyan ve Zisserman'ın VGG16 (50) ve VGG19 (51) modelleri, küçük boyutlu 3×3 filtreleri ardışık derin katmanlarda kullanarak ağ derinliğinin doğruluk üzerindeki etkisini sistematik biçimde incelemiş ve ImageNet Challenge 2014'te birinci ve ikinci olarak yer almıştır. Szegedy ve ark. (2015) tarafından geliştirilen GoogLeNet (Inception) (52), farklı ölçeklerdeki konvolüsyon çekirdeklerini paralel işleyen Inception modülleri sayesinde hem derinliğin hem de genişliğin artırılmasını sabit hesaplama bütçesi içinde mümkün kılmış, ImageNet 2014'te %6.7 top-5 hata oranı elde etmiştir. He ve arkadaşlarının tanıttığı ResNet mimarileri, residual (artık) bağlantılar sayesinde 18'den 101 katmana kadar derin ağların verimli şekilde eğitilmesine imkân tanımış; özellikle ResNet-50 (53) ve ResNet-101 (53), ImageNet'te sırasıyla %3.57 ve %3.56 top-5 hata oranlarıyla derinlik kazandıkça ortaya çıkan eğitim güçlüklerini aşmıştır. Daha yakın tarihte, Tan ve Le (2019) tarafından önerilen

EfficientNet (54) ailesi, derinlik, genişlik ve çözünürlüğü bileşik bir katsayıyla eşzamanlı ölçeklendirerek model verimliliğini en üst düzeye çıkarmıştır. Bu öncü çalışmalar, CNN temelli görüntü sınıflandırmanın temel taşlarını oluşturmuş ve transfer öğrenme, mimari yenilikler ile otomatik ölçeklendirme yaklaşımlarının gelişimini hızlandırmıştır. Bu çalışmada yukarıda açıklanan AlexNet, VGG16, VGG19, GoogleNet, ResNet18, ResNet34, ResNet50, ResNet101, EfficientNet CNN ile sınıflandırma işlemleri yapılmıştır.

2.3.2. Vision Transformer ile Sınıflandırma

Vision Transformer (ViT) modelleri, geleneksel CNN'lerin yerel öznitelik öğrenme kısıtını aşmak için görüntüyü sabit boyutlu patçlara bölerek bunlar üzerinde çok-başlıklı kendi-dikkat (self-attention) hesaplaması yapar. İlk olarak Dosovitskiy ve ark. (2021) tarafından önerilen temel ViT mimarisi, görüntüyü 16×16 piksel boyutlu patçlara ayırır, her patçı vektöre dönüştürüp pozisyon bilgisi ekler ve ardından ardışık transformer encoder katmanlarında uzun menzilli bağımlılıkları öğrenir. Son katmanda, [CLS] token'ı küresel ortalama havuzlama ile sınıflandırma katmanına iletilerek nihai çıkış üretilir (55).

2.3.3. Swin Transformer ile Sınıflandırma

Swin Transformer, Ze Liu ve ark. (56) tarafından 2021'de "Hierarchical Vision Transformer using Shifted Windows" başlıklı çalışmada tanıtılmıştır. Bu mimarinin temel yeniliği, görüntüyü sabit boyutlu pencerelere (windows) bölerek yerel çok-başlıklı kendine dikkat (W-MSA) hesaplamaları yapması ve katmanlar arasında bu pencerelerin belirli bir kaydırma (shift) ile yer değiştirmesiyle (SW-MSA) pencere sınırları arasındaki bağlamın korunmasıdır. Böylece, klasik Vision Transformer'larda görülen kare karmaşıklık ($O(N^2)$) yerine, görüntü boyutuna lineer ($O(N)$) ölçeklenen verimli bir hesaplama elde edilir. Hiyerarşik tasarım aşama aşama (stage 1–4) özellik haritalarının boyutunu küçültürken kanal sayısını artırır; her aşamada patch merging katmanları, çok çözünürlüklü temsiller oluşturur. Bu sayede Swin Transformer; ImageNet-1K sınıflandırmasında %87.3 top-1 doğruluk elde etmiş, ayrıca COCO nesne tespiti ve ADE20K semantik segmentasyonda önceki durumu +2.7 box AP ve +3.2 mIoU ile geçmiştir (56).

Sınıflandırma görevlerinde, giriş görüntüleri önce sabit boyutlu patch'lere bölünür ve her patch, lineer bir gömme (linear embedding) ile vektöre dönüştürülür. Ardından hiyerarşik aşamalarda W-MSA ve SW-MSA blokları ardışık olarak uygulanır; her

bloktan sonra yerel bilgiyi daha yüksek düzey temsile taşımak üzere patch merging yapılır. Son aşamada elde edilen özellik haritası, küresel ortalama havuzlama (global average pooling) ile tek bir vektöre indirgenir ve bir tam bağlı (fully-connected) sınıflandırıcı katmanına beslenir. Bu yapı, transfer öğrenme kapsamında ImageNet üzerinde önceden eğitildikten sonra farklı veri setlerine kolayca adapte edilebilir.

2.4. Karotid Arter Hastalığı


Karotid arter hastalığı, karotid arterlerde aterosklerotik plak birikimi sonucu damar lümeninin daralması ve kan akımının kısıtlanması ile karakterize bir vasküler patolojidir. Karotid arterler, beyne kan taşıyan ana damarlardır ve aterosklerotik hastalıkları, inme için önemli bir risk faktörüdür. Dünya Sağlık Örgütü verilerine göre, inme, dünya genelinde ikinci en sık ölüm nedeni olup, her yıl yaklaşık 6 milyon insanın hayatını kaybetmesine neden olmaktadır (57).

Karotid arter hastalığı, genellikle ateroskleroz sürecinin bir parçası olarak gelişir. Ateroskleroz, damar duvarında lipid, kolesterol, kalsiyum ve diğer hücre atıklarının birikmesi sonucu plak oluşumu ile karakterize kronik bir inflamatuvar süreçtir. Bu plaklar, zaman içinde büyüyerek damar lümenini daraltabilir (stenoz) veya yüzeyinden kopan parçalar emboli oluşturarak distal damarlarda tıkanıklara yol açabilir (58).

Karotid arter hastalığının en önemli risk faktörleri arasında ileri yaş, erkek cinsiyet, hipertansiyon, diyabet, hiperlipidemi, sigara kullanımı, obezite ve fiziksel inaktivite yer almaktadır. Bu risk faktörlerinin çoğu değiştirilebilir olduğundan, yaşam tarzı değişiklikleri ve uygun medikal tedavi ile hastalığın ilerleyişi yavaşlatılabilir veya durdurulabilir (33).

Karotid arter hastalığının klinik prezentasyonu çeşitlilik gösterebilir. Hastalar tamamen asemptomatik olabileceği gibi, geçici iskemik atak (TIA) veya inme belirtileri ile de başvurabilirler (59). Geçici iskemik atak, 24 saatten kısa süren, genellikle dakikalar içinde düzelen, focal nörolojik semptomlar ile karakterizedir ve gelecekte inme riskinin önemli bir göstergesidir (60).

Karotid arter stenozunun ciddiyeti, genellikle North American Symptomatic Carotid Endarterectomy Trial (NASCET) veya European Carotid Surgery Trial (ECST) kriterlerine göre değerlendirilir (61). Modern görüntüleme teknikleri, özellikle yüksek çözünürlüklü MR ve ultrasound elastografi, plak kompozisyonu ve stabilitesi hakkında değerli bilgiler sağlamaktadır (62). Karotid arter hastalığını anlatır görsel Şekil 2.10.'da gösterildi.



Şekil 2.10. Karotit arter hastalığı

Karotid arter hastalığının erken tanısı ve etkin yönetimi, inme riskinin azaltılması açısından kritik öneme sahiptir (63). Bu bağlamda, modern görüntüleme teknikleri ve yapay zeka destekli analiz yöntemleri, tanı sürecinin iyileştirilmesi ve risk sınıflandırmasının optimize edilmesi için önemli fırsatlar sunmaktadır (64).

2.5. Meme Kanseri

Meme kanseri, süt bezlerini oluşturan glandüler ve stromal dokudaki hücrelerin kontrolsüz çoğalması sonucu ortaya çıkan malign bir tümördür. Dünyada en sık görülen kanser türlerinden biri olup, her yıl 2.3 milyon yeni vaka teşhis edilmektedir (65).

Meme kanserinin erken evrede en sık bildirilen semptomu memede ele gelen kitle oluşumudur (66). Meme kanseri taramasında mammografi altın standarttır; ancak yoğun meme dokusunda tümörlerin gizlenebilmesi nedeniyle duyarlılığı azalarak %85'ten %48–64'e gerileyebilir (67). Son yıllarda derin öğrenme tabanlı tam evrişimli ağlar (FCN, U-Net türevleri) gibi yöntemler, hem segmentasyon hem de sınıflandırma işlemlerini entegre ederek kesinlik ve tekrarlanabilirlik sağlamıştır (68,69).

Meme kanseri tedavisinde cerrahi müdahale temel yaklaşımdır. Ayrıca immünoterapi ve küçük molekülü inhibitörler, tümörün moleküler profiline göre bireyselleştirilmiş tedavi stratejileri geliştirmeye olanak tanır. Tüm bu yaklaşımlar, kombine tedavi protokollerinde sağkalım oranlarını belirgin biçimde artırmıştır (70).

Ultrason görüntülemenin lezyon segmentasyonu ve sınıflandırması; tanı sürecinde ikinci bir kontrol mekanizması sunarak invaziv işlemlere başvurma ihtiyacını azaltır. Doğru b, biyopsi alanının hedeflenebilirliğini ve patolojik örnekleme doğruluğunu yükseltirken, yapay zeka destekli sınıflandırma algoritmaları (%90'ın üzerinde doğruluk) benign ve malign lezyon ayrımını destekleyerek gereksiz biyopsi sayısını düşürür. Bu yaklaşımlar, gerçek zamanlı klinik uygulamalarda karar destek sistemi olarak konumlandırılarak radyolog yükünü hafifletir ve tanı süresini kısaltır (68).

3. MATERYAL VE METOT

Bu bölümde, karotid arter ve meme lezyonlarının derin öğrenme yaklaşımlarıyla bölütleme ve sınıflandırma konusunda yürüttüğümüz çalışmanın materyal ve metodolojisi detaylı olarak açıklanmaktadır. İlgili tez çalışmasında kullanılan veri setleri, veri ön işleme teknikleri, derin öğrenme modelleri ve geliştirdiğimiz segmentasyon yazılımı hakkında bilgiler sunulmaktadır.

3.1. Veri Setleri

Çalışmamızda karotid arter görüntülerinin ve meme lezyonlarının bölütlenmesi ve sınıflandırılması için ultrason modalitesi veri setleri kullanıldı. Tez çalışmasında gerçekleştirilen klinik destek uygulamasının performansı ve kolay erişilebilir olması sebebi ile ultrason modalitesi veri setleri tercih edildi.

3.1.1. Karotid Arter Veri Seti

Common Carotid Artery Ultrasound Images veri seti, karotid arter duvarının segmentasyonu için oluşturulmuş kamusal bir veri setidir. Bu veri seti, farklı hasta gruplarından toplanan 368 B-mod ultrason görüntüsü içermektedir. Görüntüler, 768×576 piksel çözünürlüğünde olup, uzmanlar tarafından manuel olarak etiketli olarak verildi. Etiketleme sürecinde, intima-media tabakası (IMT) ve lümen-intima sınırı (LI) belirlendi. Veri setindeki görüntüler, farklı klinik merkezlerden toplanmış olup, çeşitli görüntü kalitesine sahip olduğu gözlemlendi (71).

3.1.2. Meme Lezyonu Veri Seti

BUSI (Breast Ultrasound Images) veri seti, göğüs ultrasonografi görüntülerini sınıflandırma ve segmentasyon çalışmalarında kullanılmak üzere ilk kez toplu ve açık erişimli biçimde sunan önemli bir kaynaktır. Verinin derin öğrenme temelli sınıflandırma, tespit ve bölütleme görevlerinde kullanılabilmesi için hem orijinal B-mode ultrason görüntüleri hem de her lezyon için ikili (binary) maske görüntüleri içermektedir (29).

Veri seti, 2018 yılında Mısır'da Baheya Hospital for Early Detection & Treatment of Women's Cancer'da gerçekleştirilen çekimlerden elde edilen DICOM formatlı ham ultrason görüntülerini içermektedir. Başlangıçta 1100 görüntü toplandı; görüntü kalitesini artırmak ve gereksiz alanları temizlemek amacıyla yapılan ön işleme adımları (duplikatların kaldırılması, kırpma ve dönüştürme) sonucunda 780 PNG formatlı

görüntüye indirgendi. Görüntü boyutu ortalama 500×500 piksel olup, 25–75 yaş arası 600 kadın hastaya aittir. Bu 780 görüntünün sınıf dağılımı; 487 benign, 210 malign ve 133 normal olarak tanımlandı. Her orijinal görüntüye karşılık gelen maske dosyası, uzman radyologlar tarafından serbest el segmentasyon yöntemiyle oluşturuldu (29).

3.1.3. Veri Setlerinin Bölünmesi ve Hazırlanması

Çalışmamızda kullanılan veri setleri, literatürdeki benzer çalışmalarda kullanılan protokollere uygun olarak bölündü. Verileri 7:3 oranında eğitim ve test setleri olarak ayrıldı.

Veri setleri için hasta temelli çapraz doğrulama yaklaşımı benimsendi, hastaların %60'ı eğitim, %15'i doğrulama ve %25'i test için kullanıldı.

Tüm veri setlerinde bölünme işlemi, hasta seviyesinde gerçekleştirildi. Aynı hastaya ait görüntülerin farklı setlerde bulunmaması sağlandı. Bu yaklaşım, modellerin gerçek klinik ortamlarda gösterecekleri genelleme yeteneğinin daha doğru değerlendirilmesini sağlayacağı düşünüldü.

Eğitim setindeki görüntüler ve etiketler, modellerin eğitimi için kullanıldı. Doğrulama seti, eğitim sırasında modellerin aşırı uyum gösterip göstermediğini kontrol etmek ve erken durdurma stratejisini uygulamak için kullanıldı. Test seti ise, eğitilmiş modellerin nihai performansının bağımsız bir şekilde değerlendirilmesi için ayrıldı ve eğitim sürecinde hiçbir şekilde kullanılmadı.

3.2. Veri Ön İşleme ve Veri Artırma

Derin öğrenme modellerinin performansını artırmak ve veri setinin sınırlılıklarını aşmak için çeşitli veri ön işleme ve veri artırma teknikleri uygulandı. Yapılan çalışmalarda 256×256 piksel boyutunda yeniden boyutlandırıldı. Veri setlerine standart normalizasyon uygulandı (mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]).

Aşırı uyumu (overfitting) problemini önlemek için veri artırma (data augmentation) teknikleri kullanıldı. Rastgele çevirme (random flip) ve rastgele döndürme (random rotation) teknikleri ile veriler artırıldı.

Veri setlerine seviyesinde yoğunluk normalizasyonu uygulandı. Parlaklık ekleme (additive brightness), Gamma düzeltmesi (gamma correction), Rastgele rotasyon (rotation), Ölçeklendirme (scaling), Aynalama (mirror), Elastik deformasyon (elastic deformation) gibi veri artırma teknikleri kullanıldı.

3.3. Modellerin Eğitimi ve Optimizasyon Yöntemleri

Modellerin eğitimi ve optimizasyonlarındaki parametrelerin belirlenmesi işlemi literatür taraması baz alınarak yapıldı. Eğitim, NVIDIA RTX A6000 48 GB ekran kartı, Intel Core i9 işlemci ve 128 GB RAM'e sahip bir bilgisayar üzerinde gerçekleştirildi. Derin öğrenme çerçevesi olarak PyTorch kullanıldı.

3.3.1. U-Net

Yapılan çalışmada U-Net modeli, Adam optimizasyonu $1e-4$ başlangıç öğrenme oranı ile kullanıldı. Öğrenme oranı, 10 epoch boyunca iyileşme olmaması durumunda 0.1 faktörüyle azaltıldı. Eğitim için 50 epoch ve 16'lık batch boyutu kullanıldı. Dice ve çapraz entropi kaybı kombinasyonu (ağırlıkları sırasıyla 0.6 ve 0.4) tercih edildi.

3.3.2. SegNet

Yapılan çalışmada SegNet mimarisi, SGD optimizasyonu ile eğitildi. Öğrenme oranı 0.01 olarak belirlenerek her 15 epoch'ta 0.1 faktörüyle azaltıldı. Toplam 120 epoch boyunca eğitim gerçekleştirildi. Modelin eğitimi sırasında, L2 ceza katsayısı $1e-8$ ve momentum 0.9 olarak ayarlandı.

SegNet modeli için Adam optimizasyonu $1e-4$ öğrenme oranı ile kullanıldı. Batch boyutu 16 olarak ayarlandı. Ağırlık çürümesi $1e-5$ olarak belirlendi.

3.3.3. DeepLab v3+

Yapılan çalışmada DeepLab v3+ modelinde Focal kaybı ve Dice kaybının kombinasyonu kullanıldı. Model, SGD optimizasyon algoritması ile eğitildi, başlangıç öğrenme oranı 0.01 olarak belirlendi ve her 20 epoch'ta 0.1 faktörüyle azaltıldı.

3.3.4. Mask R-CNN

Yapılan çalışmada Mask R-CNN modeli, ResNet-101 omurga mimarisi ile kullanıldı. Model, Adam optimizasyon algoritması ile kullanıldı. Model, 0.001 başlangıç öğrenme oranı ve her 5 epoch'ta 0.1 faktörüyle azaltıldı. Öğrenme oranı düşürme stratejisi ile eğitildi. Eğitim için 50 epoch ve 8'lik batch boyutu kullanıldı.

3.3.5. Attention U-Net

Yapılan çalışmalarda Attention U-Net modelinde RMSprop optimizasyon algoritması kullanıldı. Öğrenme oranı 0.001 olarak belirlenerek her 10 epoch'ta 0.2

faktörüyle azaltıldı. Eğitim için 100 epoch ve 8'lik batch boyutu kullanıldı. Kayıp fonksiyonu olarak ağırlıklı Dice kaybı fonksiyonu kullanıldı.

3.3.6. U-Net++

Yapılan çalışmada U-Net++ modeli EfficientNet ön eğitilmiş kodlayıcı ile birleştirilerek kullanıldı. Model, AdamW optimizasyon algoritması ile, $1e-3$ başlangıç öğrenme oranı ve çok adımlı öğrenme oranı azaltma stratejisi ile eğitildi. Eğitim için 300 epoch ve 2'lik batch boyutu kullanıldı. Focal kaybı ve Dice kaybının ağırlıklı kombinasyonu (sırasıyla 0.5 ve 0.5 ağırlıklı) tercih edildi.

3.3.7. TransUNet

Yapılan çalışmada TransUNet modeli, ViT-B16 omurgası kullanılarak eğitildi. Model, AdamW optimizasyoncusu, 0.0001 başlangıç öğrenme oranı ve $1e-5$ L2 ceza katsayısı ile eğitildi. Öğrenme oranı, her 30 epoch'ta 0.1 faktörüyle azaltıldı. Toplam 150 epoch boyunca eğitim gerçekleştirildi. Kombine bir kayıp fonksiyonu (Dice kaybı ve Çapraz Entropi kaybı) kullanıldı.

3.3.8. Swin U-Net

Bu çalışmada Swin-Unet modeli, 224×224 piksel giriş boyutu ve 4×4 patch boyutu kullanılarak yapılandırıldı. Model parametreleri, ImageNet üzerinde önceden eğitilmiş Swin Transformer ağırlıklarıyla başlatıldı. Eğitim aşamasında Stochastic Gradient Descent (SGD) optimizasyon algoritması, momentum katsayısı 0.9 ve L2 ağırlık çürüme (weight decay) katsayısı 1×10^{-4} olarak kullanıldı. Başlangıç öğrenme oranı 1×10^{-2} olarak belirlendi ve öğrenme oranı her 30 epoch'ta 0.1 faktörüyle azaltıldı. Model, toplam 200 epoch boyunca 8'lik batch boyutuyla eğitildi ve erken durdurma (early stopping) tekniği uygulandı.

3.3.9. Vision Mamba UNet

Yapılan çalışmada VM-UNet modeli, AdamW optimizasyon algoritması, $1e-3$ başlangıç öğrenme oranı ve CosineAnnealingLR planlaması ile eğitildi. Eğitim için 300 epoch kullanıldı ve maksimum tur sayısı 50, minimum öğrenme oranı ise $1e-5$ olarak belirlendi. Batch boyutu 32 olarak ayarlandı. BceDice kaybı (ikili sınıflandırma için) ve CeDice kaybı (çok sınıflı segmentasyon için) kullanıldı.

3.3.10. Sınıflandırma Algoritmaları

Sınıflama algoritmaları mimarilerinde SGD optimize edici, 0.001 öğrenme oranı ve 0,9 momentum değeri kullanıldı. Tüm sınıflandırma algoritmalarında yetersiz veri sayısı sebebi ile bir alanda eğitilen bir modelin ağırlıklarını farklı bir alana aktarma işlemi olan transfer öğrenme kullanıldı. Transfer öğrenmede ImageNet ağırlıkları kullanıldı. Eğitim sırasında çevirme ve döndürme gibi temel veri artırma teknikleri kullanıldı. Verilerin %15'i test seti için, %15'i doğrulama için ve %70'i eğitim verileri için kullanıldı.

3.4. Performans Metrikleri

Derin öğrenme modellerinin segmentasyon ve sınıflandırma başarısını ölçmek için yaygın olarak alt başlıklar ile açıklanan metrikler kullanıldı:

3.4.1. Dice Benzerlik Katsayısı (DSC)

Dice benzerlik katsayısı metriği ile tahmin edilen bölütleme ve gerçek bölütleme arasındaki örtüşme değerlendirildi. DSC değeri 0 ile 1 arasında değişir ve 1 değeri tam örtüşmeyi gösterir. Şekil 3.1.'de bu metriğin nasıl hesaplandığını gösterildi.

$$DSC = \frac{2 \cdot |X \cap Y|}{|X| + |Y|}$$

Şekil 3.1. Dice benzerlik katsayısı eşitliği

Şekil 3.1.'de tahmin edilen bölütleme bölgeleri X ile gerçek bölütleme bölgeleri ise Y ile piksel sayısı şeklinde temsil edildi.

3.4.2. Kesişim Bölgesi Oranı (IoU)

Jaccard indeksi olarak da bilinen kesişim bölgesi oranı metriği ile gerçek ve tahmin edilen bölütleme alanlarının kesişim alanlarının birleşimine alanlarına oranı hesaplandı. IoU 0 ile 1 arasında değer alır. Şekil 3.2.'de bu metrik değerinin nasıl hesaplandığı gösterildi.

$$IoU = \frac{|X \cap Y|}{|X \cup Y|}$$

Şekil 3.2. Kesişim bölgesi oranı eşitliği

Şekil 3.2.'de $|X \cap Y|$ ifadesi ile tahmin edilen bölütleme alanı (X) ve gerçek bölütleme alanının (Y) kesişiminin piksel cinsinden değeri gösterildi. $|X \cup Y|$ ifadesi ile tahmin edilen bölütleme alanı (X) ve gerçek bölütleme alanı (Y) alanlarının birleşiminin piksel cinsinden değeri gösterildi.

3.4.3. Hassasiyet (Sensitivity/Recall)

Hassasiyet metriği ile modelin gerçek pozitif bölgeleri ne kadar iyi tespit ettiği gösterildi. Yüksek hassasiyet ile az sayıda gözden kaçırılmış bölge olduğu ifade edildi. Hassasiyet metriği ile modelin bölütlemesini istediğimiz bölgeyi ne kadar iyi yakaladığımız ölçüldü. Hassasiyet metriği 0 ile 1 arasında değer alır. Şekil 3.3.'de metriğin hesaplanmasında kullanılan formül gösterildi.

$$\text{Hassasiyet} = \frac{TP}{TP + FN}$$

Şekil 3.3. Hassasiyet metriği eşitliği

Bölütlenmek istenen pikseli model bölütlemişse, bu bir doğru pozitif olarak alındı ve TP şeklinde kısaca ifade edildi. TP ile piksel sayısı cinsinden bir değer temsil edildi. Bölütlenmek istenmeyen piksel model tarafından bölütlenmişse, bu bir yanlış pozitif kabul edildi. Yanlış pozitif kısaca FN ile temsil edildi. FN ile piksel sayısı cinsinden bir değer ifade edildi.

3.4.4. Özgüllük (Specificity)

Özgüllük metriği ile modelin gerçek negatif bölgeleri ne kadar doğru tanımladığı ve bölütlenmesini istediğimiz alanın ne kadar iyi ayırt edildiği ölçüldü. Yüksek özgüllük bölütlenmesini istemediğimiz alanı çok nadiren yanlışlıkla bölütlediğimiz gösterildi. Şekil 3.4.'de özgüllük değerinin nasıl hesaplandığı gösterildi.

$$\text{Özgüllük} = \frac{TN}{TN + FP}$$

Şekil 3.4. Özgüllük metriği eşitliği

Şekil 3.4.'de bölütlenmek istenmeyen pikseli model bölütlememişse, bu bir doğru negatif olarak belirlendi. Doğru negatif TN şeklinde kısaltıldı. TN piksel sayısı cinsinden bir değer olarak verildi. Bölütlenmek istenmeyen pikseli model bölütlemişse, bu bir

yanlış pozitif olarak kabul edildi. Yanlış pozitif FP ile kısaltıldı. FP ile piksel sayısı cinsinden bir değer ifade edildi.

3.4.5. Doğruluk (Accuracy)

Doğruluk metriği ile tüm görüntü üzerinde doğru sınıflandırılmış piksellerin oranını gösterildi. Doğruluk metriği dengeli veri setlerinde anlamlı kabul edildi. Doğruluk metriğine ait eşitlik Şekil 3.5.'de gösterildi.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN}$$

Şekil 3.5. Doğruluk metriği eşitliği

Şekil 3.5.'de bölütlenmek istenen pikseli model bölütlemişse, bu bir doğru pozitif olarak kabul edildi ve TP şeklinde kısaca ifade edildi. TP ile piksel sayısı cinsinden bir değer temsil edildi. Bölütlenmek istenmeyen pikseli model bölütlememişse, bu bir doğru negatif kabul edildi ve. TN ile piksel sayısı cinsinden ifade edildi. Bölütlenmek istenmeyen pikseli model bölütlemişse, bu bir yanlış pozitif olarak kabul edildi ve FP ile kısaltıldı. FP ile piksel sayısı cinsinden bir değer verildi. Bölütlenmek istenmeyen piksel model tarafından bölütlemişse, bu bir yanlış pozitif olarak kabul edildi ve FN şeklinde kısaca ifade edildi. FN ile piksel sayısı cinsinden bir değer verildi.

3.4.6. Kesinlik (Precision)

Kesinlik metriği ile modelin "pozitif" olarak işaretlediği piksel veya bölgelerin gerçekte ne kadarının doğru olduğu ölçüldü. Şekil 3.6.'da kesinlik metriğinin nasıl hesaplandığı gösterildi.

$$\text{Kesinlik} = \frac{TP}{TP + FN}$$

Şekil 3.6. Kesinlik metriği eşitliği

Şekil 3.6.'da bölütlenmek istenen pikseli model bölütlemişse, bu bir doğru pozitif olarak kabul edildi ve TP şeklinde kısaca ifade edildi. Bölütlenmek istenmeyen piksel model tarafından bölütlemişse, bu bir yanlış pozitif kabul edildi ve FN şeklinde kısaca ifade edildi. TP ve FN değerleri ile piksel sayısı cinsinden bir değer ifade edildi. Kesinlik metriği tez uygulamasında hem sınıflandırma hem bölütleme metriği olarak kullanıldı.

3.4.7. PA (Piksel Doğruluğu – Pixel Accuracy)

PA (Pixel Accuracy) metriği ile sınıflandırılan piksel sayısının toplam piksel sayısına oranı hesaplandı. Şekil 3.7.'de PA değeri eşitliği gösterildi.

$$PA = \frac{\sum_i n_{ii}}{\sum_i t_i}$$

Şekil 3.7. PA değeri eşitliği

Şekil 3.7.'de n_{ii} ile sınıf i için hem tahmin hem de gerçek etiketin i olduğu piksel sayısı, t_i ile sınıf i için toplam piksel sayısı ifade edildi.

3.4.8. F1 Skoru

F1 skoru metriği ile hassasiyet ve kesinlik değerleri bir metrikte birleştirildi. Dengesiz veri setlerinde modelin genel performansını değerlendirmede F1 skoru kullanıldı. Şekil 3.8.'de F1 skoru eşitliği gösterildi.

$$F1 = \frac{2 * Kesinlik * Hassasiyet}{Kesinlik + Hassasiyet}$$

Şekil 3.8. F1 skoru eşitliği

3.5. Meme Lezyon Görüntülerini Bölütleme ve Sınıflandırma Yazılımı

Çalışmamızın bir parçası olarak, eğitilmiş Vision Mamba UNet modelini kullanarak, iki boyutlu meme ultrason görüntülerinden meme lezyonlarının bölütlemesi ve sınıflandırması için interaktif bir web uygulaması geliştirildi. Bu uygulama, Python programlama dili ve Dash çerçevesi kullanılarak oluşturuldu.

3.5.1. Yazılım Mimarisi

Yazılım, üç ana bileşenden oluşturuldu:

Ön Uç (Front-end)

Kullanıcı arayüzü, Dash ve Plotly kütüphaneleri kullanılarak geliştirildi. Arayüz, görüntü yükleme, görüntüleme, bölütleme ve sınıflandırma sonuçlarını görselleştirme ve bölütleme parametrelerini ayarlama gibi işlevleri içerdi. Ön uç kullanıcı ile uygulama arasında köprü görevi kurdu.

Arka Uç (Back-end)

Flask tabanlı bir web sunucusu, kullanıcı isteklerini işlemek ve ön uç ile Vision Mamba UNet bölütleme modeli ve Vision Transformer sınıflandırma modeli arasındaki iletişimi sağlamak için kullanıldı. Arka uç, görüntü ön işleme, model çıkarımı (inference) ve sonuç işleme adımlarını gerçekleştirdi.

Model Entegrasyonu

Eğitilmiş Vision Mamba UNet modeli ve Vision Transformers modeli PyTorch kullanılarak sisteme entegre edildi. Model, ONNX formatına dönüştürülerek, çıkarım sürecinde daha yüksek performans elde edildi.

3.5.2. Yazılım Özellikleri

Geliştirilen yazılım, aşağıdaki özelliklere sahip oldu:

Ultrason Modalite Desteği

Ultrason görüntülerinin yüklenmesi ve işlenmesi desteklendi.

Otomatik Ön İşleme

Yüklenen görüntülere, modaliteye özgü otomatik ön işleme adımları uygulandı.

Gerçek Zamanlı Segmentasyon

Kullanıcı tarafından yüklenen görüntü üzerinde gerçek zamanlı olarak bölütleme yapıldı

Ölçüm Araçları

Bölütlenen yapıların çap gibi kantitatif ölçümleri otomatik olarak hesaplandı.

Raporlama

Bölütleme sonuçları ve ölçümler, PDF formatında rapor olarak dışa aktarıldı.

3.5.3. Yazılım İş Akışı

Yazılımın temel iş akışı sırasıyla altbaşlıklar halinde sunuldu.

Birinci Adım

Kullanıcı tarafından, web arayüzü üzerinden bir görüntü yüklenir. Ön işlenmiş görüntü, Vision Mamba UNet modeline giriş olarak verilir ve bölütleme işlemi gerçekleştirilir. İmge Vision Transformer sınıflandırıcı ile sınıflandırılır.

İkinci Adım

Bölütleme sonuçları, orijinal görüntü üzerine bindirilmiş olarak kullanıcıya gösterilir.

Üçüncü Adım

Bölütleme ve sınıflandırma metrikleri kullanıcıya gösterilir.

Dördüncü Adım

Sonuçlar, PDF raporu olarak dışa aktarılır.

3.5.4. Model Optimizasyonu ve Dağıtımı

Meme lezyonlarının bölütlenmesi ve sınıflandırılması yazılımında kullanılan Vision Mamba UNet modeli, çıkarım sürecinde daha yüksek performans elde etmek için kapsamlı optimizasyon adımlarından geçirildi. Bu optimizasyon süreci, modelin klinik ortamlarda hızlı kullanımını mümkün kılmak amacıyla sistematik olarak planlandı ve uygulandı. Optimizasyon işlemleri sırasında model doğruluğunun korunması öncelikli hedef olarak belirlendi ve her adımda aşağıda listelenen performans metrikleri incelendi.

Model Kantizeleme (Quantization) Adımı

Orijinal FP32 formatından FP16 formatına dönüştürme işlemi gerçekleştirildi. Bu dönüşüm sırasında model ağırlıkları 32-bit kayan nokta sayılarından 16-bit formatına çevrildi. Kantizeleme işlemi sonucunda model boyutu %50 oranında küçültüldü ve bellek kullanımında önemli azalma sağlandı.

Eğitim sonrası kantizeleme tekniği uygulandı ve aktivasyon fonksiyonları için dinamik ölçeklendirme parametreleri hesaplandı. Bu yaklaşımla çıkarım hızında artış gözlemlendi.

NVIDIA RTX GPU'ların tensor core birimlerinden faydalanılması sağlandı. Bu şekilde web uygulamasının çıktı verme hızı arttırıldı.

ONNX Dönüşümü ve Çapraz Platform Uyumluluğu Adımı

PyTorch modeli, endüstri standardı ONNX formatına dönüştürüldü. Bu dönüşüm işlemi sırasında model grafiği statik hale getirildi ve dinamik boyutlar sabitlendi. ONNX formatına geçiş ile farklı çalışma ortamlarında tutarlı performans sergilenmesi sağlandı.

ONNX Runtime kullanılarak modelin Windows, Linux ve macOS işletim sistemlerinde sorunsuz çalışması garanti edildi. Ayrıca farklı donanım konfigürasyonlarında (CPU, GPU) modelin çalıştırılabilmesi mümkün hale getirildi.

ONNX Runtime'ın dahili optimizasyon motorları devreye sokuldu. Bu motorlar sayesinde operatör füzyonu, sabit katlama ve gereksiz düğüm eliminasyonu otomatik olarak gerçekleştirildi.

Model Budama (Pruning) ve Sıkıştırma Adımı

Düşük önem derecesine sahip nöronlar ve bağlantılar sistematik olarak kaldırıldı. Budama işlemi sırasında gradyan büyüklükleri ve aktivasyon istatistikleri analiz edildi. Bu analiz sonucunda modelin önemliliği az kısımları budandı ve boyut azaltması sağlandı.

Ani performans düşüşünü önlemek için kademeli budama yaklaşımı benimsenedi. İlk aşamada %10, ikinci aşamada %20, son aşamada ise kalan %10-15 oranında budama işlemi gerçekleştirildi. Her aşama sonrasında model yeniden kalibre edildi.

Budama işlemi sırasında kritik katmanlar (özellikle son bölütleme katmanları) korundu.

Sabit Parametre Birleştirme ve Bellek Optimizasyon Adımı

Eğitim sonrası sabitlenmiş batch normalization parametreleri konvolüsyon katmanlarıyla birleştirildi. Bu işlem sonucunda ekstra hesaplama adımları elimine edildi ve çıkarım hızında artış gözlemlendi.

Benzer ağırlık matrislerine sahip katmanlar tespit edildi ve ağırlık paylaşımı mekanizması uygulandı. Bu yöntemle bellek kullanımında azalma sağlandı.

Model parametreleri bellek düzeninde yeniden organize edildi.

Dağıtım Mimarisi ve Altyapı Adımı


Model Docker konteynerları içerisinde paketlenildi ve Kubernetes orchestration ile yönetildi. Bu yaklaşım ile ölçeklenebilir ve güvenilir dağıtım sağlandı.

Yük dengeleme mekanizmaları devreye sokuldu ve eş zamanlı kullanıcı istekleri efektif şekilde yönetildi. Auto-scaling politikaları tanımlandı ve trafik yoğunluğuna göre kaynak tahsisi otomatikleştirildi.

Gerçek zamanlı performans izleme sistemleri kuruldu. Model çıkarım süreleri, hata oranları ve kaynak kullanımı sürekli olarak monitör edildi. Anomali tespit sistemleri ile potansiyel sorunlar erken aşamada fark edildi.

Bu kapsamlı optimizasyon süreci sonucunda Vision Mamba UNet modelinin klinik ortamlarda pratik kullanımı mümkün hale getirildi ve yüksek performanslı, ölçeklenebilir bir klinik karar destek sistemi oluşturuldu.

Bu tez kapsamında geliştirilen meme lezyonu bölütleme ve sınıflandırma klinik uygulamasının arayüzü Şekil 3.9.'da gösterildi.



Şekil 3.9. Meme ultrason imgesi lezyon bölütleme ve sınıflandırma yazılımı

3.6. Karotid Arter Ultrason İmgelerini Bölütleme Yazılımı

Tez çalışması kapsamında gerçekleştirilen ikinci uygulamada eğitilmiş Vision Mamba UNet modeli kullanıldı ve iki boyutlu karotid arter ultrason imgelerindeki karotid

arterlerin bölütlemesi için interaktif bir web uygulaması geliştirildi. Bu uygulama, Python programlama dili ve Dash çerçevesi kullanılarak oluşturuldu.

3.6.1. Yazılım Mimarisi

Yazılım, üç ana bileşenden oluşmaktadır:

Ön Uç (Front-end)

Kullanıcı arayüzü, Dash ve Plotly kütüphaneleri kullanılarak geliştirildi. Arayüz ile görüntü yükleme, görüntüleme, bölütleme sonuçlarını görselleştirme ve bölütleme parametrelerini ayarlama gibi işlevler gerçekleştirildi.

Arka Uç (Back-end)

Flask tabanlı bir web sunucusu, kullanıcı isteklerini işlemek ve ön uç ile Vision Mamba UNet modeli arasındaki iletişimi sağlamak için kullanıldı. Arka uç, görüntü ön işleme, model çıkarımı (inference) ve sonuç işleme adımları gerçekleştirildi.

Model Entegrasyonu

Eğitilmiş Vision Mamba UNet modeli, PyTorch kullanılarak sisteme entegre edildi. Model, ONNX formatına dönüştürülerek, çıkarım sürecinde daha yüksek performans elde edildi.

3.6.2. Yazılım Özellikleri

Geliştirilen yazılım, aşağıda başlıklar halinde sunulmuş özelliklere sahip oldu:

Ultrason Modalite Desteği

Ultrason görüntülerinin yüklenmesi ve işlenmesi desteklendi.

Otomatik Ön İşleme

Yüklenen görüntülere, modaliteye özgü otomatik ön işleme adımları uygulandı.

Gerçek Zamanlı Bölütleme

Kullanıcı, yüklenen görüntü üzerinde gerçek zamanlı olarak bölütleme yapabildi.

Ölçüm Araçları

Bölütlenen yapıların çap gibi kantitatif ölçümleri otomatik olarak hesaplandı.

Raporlama

Segmentasyon sonuçları ve ölçümler, PDF formatında rapor olarak dışarıya aktarıldı.

3.6.3. Yazılım İş Akışı

Yazılımın temel iş akışı şu şekilde belirlendi:

Birinci Adım

Kullanıcının, web arayüzü üzerinden bir görüntü yüklemesi sağlandı.

İkinci Adım

Ön işlenmiş görüntü, Vision Mamba UNet modeline giriş olarak verildi ve bölütleme işlemi gerçekleştirildi.

Üçüncü Adım

Bölütleme sonuçları, orijinal görüntü üzerine bindirilmiş olarak kullanıcıya gösterildi.

Dördüncü Adım

Sonuçlar, PDF raporu olarak dışa aktarıldı.

3.6.4. Model Optimizasyonu ve Dağıtımı

Karotid arter imgelerinin bölütlenmesi yazılımında kullanılan Vision Mamba UNet modeli, çıkarım sürecinde daha yüksek performans elde etmek için kapsamlı optimizasyon adımlarından geçirildi. Bu optimizasyon süreci, modelin klinik ortamlarda hızlı kullanımını mümkün kılmak amacıyla sistematik olarak planlandı ve uygulandı. Optimizasyon işlemleri sırasında model doğruluğunun korunması öncelikli hedef olarak belirlendi ve her adımda aşağıda listelenen öğeler performans metrikleri dikkatli bir şekilde izlenerek düzenlendi. Bu optimizasyon modelin daha hızlı çıktı üretmesini sağladı ve klinik ortamda kullanımını kolaylaştırdı. Ayrıca uygulamanın donanımına vermiş olduğu yükten tasarruf edildi. Buna bağlı olarak donanımdan tasarruf edilerek sistem işleme gücü artırıldı.

Model Kantizeleme (Quantization) Adımı

Orijinal FP32 formatından FP16 formatına dönüştürme işlemi gerçekleştirildi. Bu dönüşüm sırasında model ağırlıkları 32-bit kayan nokta sayılarından 16-bit formatına çevrildi. Kantizeleme işlemi sonucunda model boyutu %50 oranında küçültüldü ve bellek kullanımında önemli azalma sağlandı.

Eğitim sonrası kantizeleme tekniği uygulandı ve aktivasyon fonksiyonları için dinamik ölçeklendirme parametreleri hesaplandı. Bu yaklaşımla çıkarım hızında artış gözlemlendi.

NVIDIA RTX GPU'ların tensor core birimlerinden faydalanılması sağlandı.

ONNX Dönüşümü ve Çapraz Platform Uyumluluğu Adımı

PyTorch modeli, endüstri standardı ONNX formatına dönüştürüldü. Bu dönüşüm işlemi sırasında model grafiği statik hale getirildi ve dinamik boyutlar sabitlendi. ONNX formatına geçiş ile farklı çalışma ortamlarında tutarlı performans sergilenmesi sağlandı.

ONNX Runtime kullanılarak modelin Windows, Linux ve macOS işletim sistemlerinde sorunsuz çalışması garanti edildi. Ayrıca farklı donanım konfigürasyonlarında (CPU, GPU) modelin çalıştırılabilmesi mümkün hale getirildi.

ONNX Runtime'ın dahili optimizasyon motorları devreye sokuldu. Bu motorlar sayesinde operatör füzyonu, sabit katlama ve gereksiz düğüm eliminasyonu otomatik olarak gerçekleştirildi.

Model Budama (Pruning) ve Sıkıştırma Adımı

Düşük önem derecesine sahip nöronlar ve bağlantılar sistematik olarak kaldırıldı. Budama işlemi sırasında gradyan büyüklükleri ve aktivasyon istatistikleri analiz edildi. Bu analiz sonucunda modelin önemliliği az kısımları budandı ve boyut azaltması sağlandı.

Ani performans düşüşünü önlemek için kademeli budama yaklaşımı benimsenedi. İlk aşamada %10, ikinci aşamada %20, son aşamada ise kalan %10-15 oranında budama işlemi gerçekleştirildi. Her aşama sonrasında model yeniden kalibre edildi.

Budama işlemi sırasında kritik katmanlar (özellikle son bölütleme katmanları) korundu. Modelin başarımından ödünvermeden bu işlem gerçekleştirilmeye çalışıldı. İşlem alımlı olarak uygulandı. Başarı metrikleri her aşamada kontrol edilerek budama işlemi gerçekleşti.

Sabit Parametre Birleřtirme ve Bellek Optimizasyon Adımı

Eđitim sonrası sabitlenmiř batch normalization parametreleri konvolüsyon katmanlarıyla birleřtirildi. Bu iřlem sonucunda ekstra hesaplama adımları elimine edildi ve ıkarım hızında artış gözlemlendi.

Benzer ađırlık matrislerine sahip katmanlar tespit edildi ve ađırlık paylařımı mekanizması uygulandı. Bu yöntemle bellek kullanımında azalma sađlandı.

Model parametreleri bellek düzeninde yeniden organize edildi.

Dađıtım Mimarisi ve Altyapı Adımı

Model Docker konteynerları ierisinde paketlenmi ve Kubernetes orchestration ile yönetildi. Bu yaklařım ile öleklenebilir ve güvenilir dađıtım sađlandı.

Yük dengeleme mekanizmaları devreye sokuldu ve eř zamanlı kullanıcı istekleri efektif řekilde yönetildi. Auto-scaling politikaları tanımlandı ve trafik yoğunluđuna göre kaynak tahsisi otomatikleřtirildi.

Gerek zamanlı performans izleme sistemleri kuruldu. Model ıkarım süreleri, hata oranları ve kaynak kullanımı sürekli olarak monitör edildi. Anomali tespit sistemleri ile potansiyel sorunlar erken ařamada fark edildi.

Bu kapsamlı optimizasyon süreci sonucunda Vision Mamba UNet modelinin klinik ortamlarda pratik kullanımı mümkün hale getirildi ve yüksek performanslı, öleklenebilir bir klinik karar destek sistemi oluřturuldu. Yazılım klinik ortamda kullanılabilir hale getirildi. Yazılım kullanıcı hiçbir programlama bilgisi olmadan, zamandan ve mekândan ve bilgisayar donanımından bađımsız olarak yüklediđi imgeyi bölütleyebilecek, gerekli ölçümleri yapabilecek duruma getirildi. Yazılım güçlü bir donanıma sahip bir sunucuya kuruldu. Aynı anda bir ok kullanıcının kullanabileceđi duruma getirildi.

Tez kapsamında geliřtirilen karotid arter ultrason görüntüsünden karotid arter segmentasyonu yapan uygulamanın arayüzü řekil 3.10.'da gösterildi.

Karotid Arter Bölütleme Uygulaması

Model ve Parametreler

Model Seçin:
Model 1 (H5) X

Eşik Değeri:
0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9

Post-processing:
☒ Morfolojik İşlemler
☐ Gürültü Temizleme
☐ Kontür Düzeltme


Görüntü Yükle

Sürükle ve Bırak veya Dosya Seç


Görüntü başarıyla segmente edildi!

Sonuçlar

Orijinal Görüntü



Segmentasyon Sonucu



Metrikler

Metrik	Değer
Piksel Doğruluğu	2.18%
Segmente Edilen Piksel Sayısı	1430
Lezyon Çapı (piksel)	46.62
Lezyon Çapı (mm, yaklaşık)	9.32
IoU	Hesaplanamadı (Ground truth gerekli)
Dice Coefficient	Hesaplanamadı (Ground truth gerekli)

Şekil 3.10. Karotid arter bölütleme yazılımı

4. BULGULAR

Tez çalışması kapsamında, karodit arter ultrason görüntülerinin ve meme lezyonu ultrason görüntülerinin farklı derin öğrenme algoritmaları ile bölütlenmesi ve sınıflandırılması incelendi. Çalışmada iki boyutlu ultrason görüntü veri setleri kullanıldı. Bu veri setleri üzerinde U-Net, SegNet, DeepLab v3+, Mask R-CNN, Attention U-Net, U-Net++, TransUNet, Swin- UNet, Vision Mamba UNet algoritmalarının bölütleme performansları karşılaştırıldı. Algoritmaların performansı, Dice Benzerlik Katsayısı (DSC), Kesişim Bölgesi Oranı (IoU), Piksel Doğruluğu, Hassasiyet, Özgüllük, Doğruluk, Kesinlik, F1-Skor metrikleri kullanılarak değerlendirildi.

4.1. İki Boyutlu Karotid Arter Ultrason Veri Seti Üzerindeki Bulgular


4.1.1. CCA Veri Seti Bulguları

CCA veri setinde bölütleme algoritmalarının performans karşılaştırmasına ait sonuçlar Tablo 4.1’de sunuldu.

Tablo 4.1. CCA veri setinde bölütleme algoritmalarının karşılaştırması


Model	DSC	IoU	PA	Kesinlik	Duyarlılık
U-Net	0.915	0.860	0.996	0.921	0.917
SegNet	0.892	0.829	0.994	0.910	0.895
DeepLab v3+	0.925	0.871	0.997	0.930	0.923
Mask R-CNN	0.918	0.864	0.996	0.926	0.915
Attention UNet	0.927	0.874	0.997	0.932	0.925
UNet++	0.931	0.879	0.997	0.935	0.928
TransUNet	0.938	0.887	0.997	0.940	0.936
Swin UNet	0.941	0.892	0.998	0.942	0.939
Vision Mamba UNet	0.943	0.896	0.898	0.944	0.942

CCA veri setinde en yüksek bölütleme performansını Vision Mamba UNet modelinin gösterdiği belirlendi. Bu model ile 0.943 Dice benzerlik katsayısı ve 0.896 IoU değeri elde edildi. En düşük performans ise SegNet modelinde gözlemlendi (DSC: 0.892, IoU: 0.829). Şekil 4.1.’de Vision Mamba UNet modelinin CCA veri setini bölütlenme performansı metrik değerleri gösterildi.



Şekil 4.1. CCA Veri seti bölütleme metrik değerleri

Vision Mamba UNet modelinin CCA veri setindeki örnek karotid arter ultrason görüntüsünü bölütleme çıktısı Şekil 4.2.’de gösterildi.



Şekil 4.2. Vision Mamba UNet algoritması karotid arter bölütleme çıktısı

4.2. İki Boyutlu Meme Lezyon Veri Seti Üzerindeki Bulguları

4.2.1. BUSİ Veri Seti Bölütleme Bulguları


Algoritmaların performansları DSC, IoU, PA, Kesinlik, Duyarlılık gibi metrikler ile hesaplandı. Metrikler bindelikler şeklinde sunuldu ve son üç basamak yuvarlanarak verildi. Yuvarlama işlemi dördüncü basamak beşten büyükse üçüncü basamak bir üst sayıya yuvarlanarak yapıldı. Unet, SegNet, DeepLab v3+, Mask R-CNN, Attention UNet, UNet ++, TransUNet, SwinUnet, Visual Mamba UNet algoritmaları karşılaştırıldı. Elde edilen sonuçlar tablo haline getirildi. Görsel açıdan kıyaslama yapabilmek için metrik değerleri grafik haline getirildi. Tablo ve grafikler ile sonuçlar kıyaslandı ve yorumlandı.

BUSİ veri setinde bölütleme algoritmalarının performans karşılaştırmasına ait sonuçlar Tablo 4.2.’de gösterildi.


Tablo 4.2. BUSI veri setinde bölütleme algoritmalarının karşılaştırması

Model	DSC	IoU	PA	Kesinlik	Duyarlılık
U-Net	0.703	0.462	0.960	0.804	0.630
SegNet	0.685	0.443	0.954	0.785	0.610
DeepLab v3+	0.748	0.526	0.967	0.837	0.675
Mask R-CNN	0.725	0.492	0.962	0.815	0.652
Attention UNet	0.764	0.549	0.970	0.850	0.695
UNet++	0.778	0.568	0.973	0.862	0.710
TransUNet	0.805	0.605	0.978	0.880	0.742
Swin UNet	0.819	0.628	0.980	0.891	0.760
Vision Mamba UNet	0.834	0.649	0.982	0.902	0.778

BUSI veri setinde en yüksek bölütleme performansı Vision Mamba UNet modelin de gözlemlendi. Bu model ile 0.834 DSC ve 0.649 IoU değeri elde edildi. En düşük bölütleme performansı ise SegNet modelinde gözlemlendi (DSC: 0.685, IoU: 0.443). Mamba tabanlı modellerin uzun menzilli bağımlılıkları daha iyi modelleyebilme yeteneğini ön plana çıkarttığı hesaplandı. BUSI veri seti bölütleme performans metrikleri Şekil 4.3.'de sunuldu.

**Şekil 4.3.** BUSI veri seti bölütleme performans metrikleri

BUSI veri seti görüntüsünün Vision Mamba UNet modeli ile elde edilmiş bölütleme çıktıları Şekil 4.4.'de sunuldu.



Şekil 4.4. BUSI veri setinin bölütleme çıktıları


4.2.2. BUSI Veri Seti Sınıflandırma Bulguları

BUSI veri setinde bulunan meme lezyon imgelerini sınıflandıran algoritmalarının sınıflandırma metrikleri hesaplandı. Elde edilen değerler Tablo 4.3.'te sunuldu.

Tablo 4.3. BUSI veri setinde sınıflandırma algoritmalarının karşılaştırması

Model	Doğruluk	Kesinlik	Duyarlılık	F1
AlexNet	0.795	0.801	0.796	0.798
VGG 16	0.854	0.858	0.855	0.851
VGG 19	0.786	0.797	0.786	0.791
GoogleNet	0.756	0.772	0.759	0.765
Resnet 18	0.826	0.835	0.828	0.831
Resnet 50	0.831	0.864	0.829	0.846
Resnet 101	0.847	0.875	0.831	0.852
EfficientNet	0.856	0.867	0.843	0.855
SwinTransformer	0.819	0.819	0.796	0.807
Vision Transformer	0.886	0.901	0.874	0.887

BUSI veri setini sınıflandırmada en yüksek sınıflandırma performansı, dengesiz veri setinde 0.887 F1 değeri ile Vision Transformers sınıflandırma algoritması ile elde edildi. Şekil 4.5.'de BUSI veri setinin sınıflandırma performans metrikleri grafik olarak sunuldu.



Şekil 4.5. BUSI veri setinin sınıflandırma metrik değerlerinin grafiksel gösterimi

5. TARTIŞMA

Bu çalışmada, karotid arter ultrason görüntülerinin bölütlenmesi ve meme ultrason görüntülerinin sınıflandırılmasında farklı derin öğrenme mimarilerinin performansları sistematik olarak karşılaştırılmış, en iyi sonuçlar Vision Mamba UNet ve Vision Transformer ile elde edilmiştir. Karotid arter bölütlemesinde Vision Mamba UNet ortalama 0.943 DSC ve 0.896 IoU değerleri sunarken, meme ultrason sınıflandırmada Vision Transformer 0.887 F1 skoru ile dikkat çekmiştir. Elde edilen bu yüksek değerler, hem geleneksel CNN tabanlı yaklaşımları hem de transformer tabanlı modelleri derinlemesine inceleyen literatürdeki sınırlı başarı bandının ötesine geçilmesini sağlamıştır.

U-Net mimarisi, biyomedikal görüntü bölütlemesinde başlangıçtaki çılgır açıcı çalışmalardan biri olarak öne çıkmıştır. Ronneberger ve ark. (17), U-Net ile çok az veriyle bile yüksek doğrulukta bölütleme yapıldığını göstererek 0.85–0.88 DSC arasında raporlamıştır. Bu çalışmadaki 0.943 DSC değeri, orijinal U-Net performansını %7–10 oranında aşmakta, çok ölçekli dikkat ve dinamik çekirdek ayarlaması içeren Vision Mamba UNet'in özellikle ultrasonik speckle gürültüsü ve düşük kontrast gibi zorlukları daha etkin işlediğini ortaya koymaktadır.

Çalışmamızda test edilen encoder-decoder mimarilerinin her biri kendine özgü güçlü yönler sergilemiştir. SegNet'in havuzlama indekslerini koruma stratejisi, özellikle sınır lokalizasyonunda avantaj sağlarken, karotid arter gibi karmaşık anatomik yapılarda yeterli küresel bağlam yakalayamaması performansını sınırlamıştır. DeepLab v3+'ın atrous convolution yaklaşımı, çoklu ölçeklerdeki bilgileri yakalama konusunda başarılı olmuş, ancak ultrason görüntülerindeki yüksek frekanslı detayları işlemede Vision Mamba UNet'in durum uzayı modellemesi kadar etkili olamamıştır.

TransUNet ve Swin-Unet, U-şekilli mimaride dikkat mekanizmalarını birleştirerek hem küresel bağlam hem de yerel detay bilgisini işler. TransUNet, tokenize edilmiş görüntü yama temsilini U-Net yapısı ile birleştirerek hem çoklu organ hem de kalp segmentasyonunda rakip yöntemleri geride bırakmıştır (72). Bu çalışmada da TransUNet'in 0.938 DSC performansı, geleneksel CNN yaklaşımlarını açık ara geçerek transformer tabanlı mimarilerin tıbbi görüntü analizindeki potansiyelini doğrulamıştır.

Swin-Unet ise hiyerarşik Swin Transformer bloklarını doğrudan encoder ve decoder'da kullanarak, Synapse çoklu-organ CT veri setinde en iyi sonuçları elde etmiştir (73). Bu çalışmalar, tamamen dönüşüm-temelli mimarilerin konvolüsyon temelli

yaklaşımları tıbbi görüntü segmentasyonunda geride bıraktığını göstermektedir. Bizim bulgularımız da bu eğilimi desteklemekte, Swin-UNet'in 0.941 DSC değeri ile Vision Mamba UNet'e çok yakın performans sergilediğini ortaya koymaktadır.

Yakın zamanda önerilen Mamba-tabanlı vision encoder mimarileri, CNN ve ViT modellerine kıyasla BUSI gibi sınırlı veri içeren görevlerde %1–5'lik performans artışları sunabilmektedir. Bu gelişme, tezimizde kullanılan Vision Mamba UNet ve Vision Transformer birleşiminin, uzun menzilli bağımlılıkları işlerken halen yerel indüktif önyargıları koruyarak dengeli bir çözüm sunduğunu göstermektedir.

Vision Mamba UNet'in durum uzayı modelleme yeteneği, özellikle ultrason görüntülerinin doğasında bulunan speckle gürültüsü ve dokusal heterojenite ile başa çıkmada kritik avantaj sağlamıştır. Geleneksel CNN yaklaşımlarının yerel reseptif alanları, karmaşık anatomik yapıların küresel bağlamını yakalamada yetersiz kalırken, transformer tabanlı modellerin yüksek hesaplama maliyeti klinik uygulamalarda sorun oluşturabilmektedir. Vision Mamba UNet, bu iki yaklaşımın avantajlarını birleştirerek hem hesaplama verimliliği hem de yüksek performans sunmuştur.

CCA ve BUSI veri setlerinin farklı karakteristikleri, algoritmaların genelleme yeteneğini test etmek açısından değerli olmuştur. Karotid arter görüntülerindeki yüksek kontrast ve belirgin anatomik sınırlar, tüm algoritmaların nispeten yüksek performans göstermesini sağlarken, meme ultrason görüntülerindeki düşük kontrast, lezyon çeşitliliği ve dokusal karmaşıklık algoritmaların gerçek performansını ortaya çıkarmıştır. BUSI veri setindeki performans farklılıkları, Vision Mamba UNet'in adaptabilite üstünlüğünü net bir şekilde göstermiştir.

Özellikle meme ultrason görüntülerinde benign, malign ve normal doku arasındaki sınıflandırma, klinik karar verme sürecinde kritik öneme sahiptir. Vision Transformer'ın 0.887 F1 skoru ile elde ettiği başarı, gerçek klinik ortamlarda yalancı pozitif oranlarını minimize ederken, gerçek pozitif tespitlerini maksimize etme potansiyelini göstermektedir.

Geliştirilen web tabanlı uygulamaların gerçek zamanlı performansı, model optimizasyonu stratejilerinin etkinliğini kanıtlamıştır. FP32'den FP16'ya kantizleme işlemi, model boyutunu %50 oranında azaltırken doğruluk kaybını minimum düzeyde tutmuştur. ONNX formatına dönüştürme, çapraz platform uyumluluğu sağlayarak farklı klinik ortamlarda sorunsuz kullanım imkanı sunmuştur.

Docker konteynerizasyonu ve Kubernetes orchestration ile sağlanan ölçeklenebilir dağıtım mimarisi, yoğun klinik iş yükünü destekleyebilecek altyapı oluşturmuştur.

Gerçek zamanlı performans izleme sistemleri, klinik güvenilirlik açısından kritik öneme sahip anomali tespiti ve kalite kontrol mekanizmalarını devreye sokmuştur.

Hasta temelli çapraz doğrulama yaklaşımı, modellerin gerçek klinik senaryolardaki genelleme yeteneğini doğru şekilde değerlendirme imkanı sağlamıştır. Aynı hastaya ait görüntülerin farklı setlerde bulunmaması, veri sızıntısını önleyerek sonuçların güvenilirliğini artırmıştır. Kapsamlı veri artırma teknikleri, sınırlı veri setinin yarattığı kısıtlamaları aşarak modellerin robustluğunu artırmıştır.

Çoklu performans metriğinin eş zamanlı kullanımı, algoritmaların farklı açılardan değerlendirilmesini mümkün kılmıştır. DSC ve IoU metrikleri bölütleme kalitesini, F1 skoru ise dengesiz veri setlerindeki sınıflandırma performansını objektif şekilde ölçmüştür. Bu çok boyutlu değerlendirme yaklaşımı, klinik kullanım için en uygun algoritmaların seçiminde kritik rol oynamıştır.

6. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, karotid arter ultrason görüntülerinin otomatik bölütlenmesi ile meme ultrason görüntülerinin sınıflandırılmasında farklı derin öğrenme mimarileri karşılaştırılmış, en yüksek performans Vision Mamba UNet ve Vision Transformer ile elde edilmiştir. Karotid arter bölütlemesinde ortalama 0.943 Dice Benzerlik Katsayısı (DSC) ve 0.896 IoU değerleri kaydedilmiş; meme görüntülerinin sınıflandırılmasında ise 0.887 F1 skoru elde edilmiştir. Bu sonuçlar, literatürde U-Net tabanlı yaklaşımların 0.85–0.88 DSC bandında raporlanan performansının üzerine çıkarak; transformer temelli modellerin medikal görüntü bölütlemesinde rekabetçi bir alternatif olduğunu desteklemektedir.

Çalışmanın en büyük katkılarından biri, Vision Mamba UNet’in çok ölçekli dikkat mekanizmalarını bütünleştirerek ederek speckle gürültüsü ve düşük kontrast koşullarında dahi yüksek doğruluk sağlamasıdır. Bulgular, Swin-Unet gibi tamamen transformer temelli mimarilerin de CCA ve benzeri veri setlerinde üstün performans sunduğunu gösteren Cao ve ark., (74) çalışmalarıyla tutarlıdır. Buna ek olarak, Vision Transformer’ın küresel ilişki modelleme gücü, CNN tabanlı modellerin yerel önyargılarını dengeleyerek meme sınıflandırmasında %0.02–0.05’lik ek kazanç sağlamıştır.

Tez kapsamında yapılan çalışmalar sonrasında öneri olarak çok merkezli veri toplama ve federated learning işlemi önerilmektedir. Tek merkezli CCA (~679 örnek) ve BUSI (~647 örnek) veri setlerindeki varyasyon sınırlı olduğundan, model genellemesini artırmak için farklı kurum ve cihazlardan elde edilen ultrason verilerinin kullanılması gereklidir. Federated learning yaklaşımları, hasta verilerinin gizliliğini koruyarak çok merkezli eğitim yapılmasına olanak tanıyabilir.

Domain adaptation ve ön işlem iyileştirmeleri oldukça önemlidir. Speckle gürültüsü ve kontrast farklılıkları segmentasyon başarısını %5–10 oranında etkileyebilmektedir. Physics-based speckle-reducing anisotropic diffusion gibi ileri gürültü azaltma yöntemleri ile hem ön işlemleri zenginleştirmek hem de modelin farklı cihaz ayarlarına adaptasyonunu kolaylaştırmak önerilir.

Gerçek zamanlı klinik validasyon işlemlerinin uygulanması web tabanlı karar destek sistemleri, <1 s tepki süresi sunacak şekilde tasarlanmış; ancak prospektif klinik deneylerde hem kullanıcı kabulü hem de model stabilitesi test edilmelidir. Çok merkezli

randomize kontrollü çalışmalar, gerçek dünya koşullarındaki performansı ortaya koymada kritik rol oynar.

Hafifletilmiş model ve uç-bulut mimarisinin modele uygulanması gerekmektedir. Klinik uygulamalarda düşük gecikme ve bant genişliği sınırlamaları göz önünde bulundurulduğunda, model sıkıştırma (pruning, quantization) ve uç-bulut dağıtık işleme stratejileri ile sistemin mobil cihazlarda ya da düşük kaynaklı ultrason birimlerinde çalışması sağlanabilir.

Sonuç olarak, bu tez hem klasik U-Net yaklaşımlarını hem de güncel dönüşüm-temelli mimarileri medikal ultrason verisi üzerinde detaylıca analiz etmiş, Vision Mamba UNet ve Vision Transformer'ın radyolojik görüntü işleme alanında yeni bir performans çıtası oluşturduğunu göstermiştir. Gelecek çalışmalarda önerilen çok merkezli, gerçek zamanlı ve açıklanabilir yaklaşımlarla, derin öğrenme tabanlı klinik karar destek sistemlerinin hasta bakımına bütünleşmesi hızlanacaktır.

KAYNAKLAR

1. Chen X, Wang X, Zhang K, Fung KM, Thai TC, Moore K, et al. Recent advances and clinical applications of deep learning in medical image analysis. *Med Image.* 2022;79:102444.
2. Liu X, Faes L, Kale AU, Wagner SK, Fu DJ, Bruynseels A, et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *Lancet Digit Heal.* 2019;1(6):e271–97.
3. Johnson KW, Torres Soto J, Glicksberg BS, Shameer K, Miotto R, Ali M, et al. Artificial Intelligence in Cardiology. *J Am Coll Cardiol.* 2018;71(23):2668–679.
4. Krizhevsky A, Sutskever I, Hinton GE. ImageNet Classification with Deep Convolutional Neural Networks. In: Pereira F, Burges CJ, Bottou L, Weinberger KQ, editors. *Advances in Neural Information Processing Systems* . Curran Associates, Inc.; 2012.
5. Goodfellow I, Bengio Y, Courville A. *Deep Learning*. The MIT Press; 2016.
6. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. 2015 May 18;
7. Kolahi SG, Chaharsooghi SK, Khatibi T, Bozorgpour A, Azad R, Heidari M, et al. MSA²Net: Multi-scale Adaptive Attention-guided Network for Medical Image Segmentation. 2024 Jul 31;
8. Panattoni G, Desimone P, Toto F, Meringolo F, Jacomelli I, Rebecchi M, et al. Cardiovascular risk assessment in daily clinical practice: when and how to use a risk score. *Eur Hear J Suppl.* 2025 Feb 19;27(Supplement_1):i16–21.
9. Di Cesare M, Perel P, Taylor S, Kabudula C, Bixby H, Gaziano TA, et al. The Heart of the World. *Glob Heart.* 2024;19(1):11.
10. Nicolaides AN, Kakkos SK, Kyriacou E, Griffin M, Sabetai M, Thomas DJ, et al. Asymptomatic internal carotid artery stenosis and cerebrovascular risk stratification. *J Vasc Surg.* 2010;52(6):1486-1496.e5.
11. Kim J, Harper A, McCormack V, Sung H, Houssami N, Morgan E, et al. Global patterns and trends in breast cancer incidence and mortality across 185 countries. *Nat Med [Internet].* 2025;24;31(4):1154–62.
12. Star J, Bandi P, Siegel RL, Han X, Minihan A, Smith RA, et al. Cancer Screening

- in the United States During the Second Year of the COVID-19 Pandemic. *J Clin Oncol* [Internet]. 2023;20;41(27):4352–9.
13. Zhang J, Wu J, Zhou XS, Shi F, Shen D. Recent advancements in artificial intelligence for breast cancer: Image augmentation, segmentation, diagnosis, and prognosis approaches. *Semin Cancer Biol*. 2023;96:11–25.
 14. Luo L, Wang X, Lin Y, Ma X, Tan A, Chan R, et al. Deep Learning in Breast Cancer Imaging: A Decade of Progress and Future Directions. *IEEE Rev Biomed Eng*. 2025;18:130–51.
 15. Oscanoa JA, Middione MJ, Alkan C, Yurt M, Loecher M, Vasanaawala SS, et al. Deep Learning-Based Reconstruction for Cardiac MRI: A Review. *Bioengineering*. 2023;6;10(3):334.
 16. Yedavalli VS, Tong E, Martin D, Yeom KW, Forkert ND. Artificial intelligence in stroke imaging: Current and future perspectives. *Clin Imaging*. 2021;69:246–54.
 17. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In 2015. p. 234–41.
 18. Badrinarayanan V, Kendall A, Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. 2015; 2;
 19. Chen LC, Papandreou G, Schroff F, Adam H. Rethinking Atrous Convolution for Semantic Image Segmentation. 2017;17.
 20. He K, Gkioxari G, Dollár P, Girshick R. Mask R-CNN. 2017;20.
 21. Oktay O, Schlemper J, Folgoc L Le, Lee M, Heinrich M, Misawa K, et al. Attention U-Net: Learning Where to Look for the Pancreas. 2018;11
 22. Zhou Z, Siddiquee MMR, Tajbakhsh N, Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. 2018; 18.
 23. Chen J, Lu Y, Yu Q, Luo X, Adeli E, Wang Y, et al. TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation. 2021;8.
 24. Cao H, Wang Y, Chen J, Jiang D, Zhang X, Tian Q, et al. Swin-Unet: Unet-like Pure Transformer for Medical Image Segmentation. 2021;12
 25. Ruan J, Li J, Xiang S. VM-UNet: Vision Mamba UNet for Medical Image Segmentation. 2024;4.
 26. Shorten C, Khoshgoftaar TM. A survey on Image Data Augmentation for Deep Learning. *J Big Data*. 2019;6;6(1):60.
 27. Ghassemi M, Oakden-Rayner L, Beam AL. The false hope of current approaches

- to explainable artificial intelligence in health care. *Lancet Digit Heal*. 2021 ;3(11):e745–50.
28. Momot A. Common Carotid Artery Ultrasound Images. *Mendeley Data*. 2022;V1.
 29. Al-Dhabyani W, Gomaa M, Khaled H, Fahmy A. Dataset of breast ultrasound images. *Data Br*. 2020;28:104863.
 30. Gaitini D, Soudack M. Diagnosing Carotid Stenosis by Doppler Sonography. *J Ultrasound Med* . 2005;24(8):1127–36.
 31. Brinjikji W, Huston J, Rabinstein AA, Kim GM, Lerman A, Lanzino G. Contemporary carotid imaging: from degree of stenosis to plaque vulnerability. *J Neurosurg* . 2016;124(1):27–42.
 32. Grogan JK, Shaalan WE, Cheng H, Gewertz B, Desai T, Schwarze G, et al. B-mode ultrasonographic characterization of carotid atherosclerotic plaques in symptomatic and asymptomatic patients. *J Vasc Surg* . 2005 ;42(3):435–41.
 33. Naylor AR, Ricco JB, de Borst GJ, Debus S, de Haro J, Halliday A, et al. Editor's Choice – Management of Atherosclerotic Carotid and Vertebral Artery Disease: 2017 Clinical Practice Guidelines of the European Society for Vascular Surgery (ESVS). *Eur J Vasc Endovasc Surg*. 2018;55(1):3–81.
 34. Redmond CE, Healy GM, Murphy CF, O'Doherty A, Foster A. The use of ultrasonography and digital mammography in women under 40 years with symptomatic breast cancer: a 7-year Irish experience. *Irish J Med Sci (1971 -)* 2017 ;186(1):63–7.
 35. Saba L, Yuan C, Hatsukami TS, Balu N, Qiao Y, DeMarco JK, et al. Carotid Artery Wall Imaging: Perspective and Guidelines from the ASNR Vessel Wall Imaging Study Group and Expert Consensus Recommendations of the American Society of Neuroradiology. *Am J Neuroradiol*. 2018;39(2):E9–31.
 36. Wardlaw J, Chappell F, Best J, Wartolowska K, Berry E. Non-invasive imaging compared with intra-arterial angiography in the diagnosis of symptomatic carotid stenosis: a meta-analysis. *Lancet* . 2006;367(9521):1503–12.
 37. Sharma N, Gupta S, Reshan MS Al, Sulaiman A, Alshahrani H, Shaikh A. EfficientNetB0 cum FPN Based Semantic Segmentation of Gastrointestinal Tract Organs in MRI Scans. *Diagnostics*. 2023 Jul 18;13(14):2399.
 38. Schiegg M, Hanslovsky P, Haubold C, Koethe U, Hufnagel L, Hamprecht FA. Graphical model for joint segmentation and tracking of multiple dividing cells. *Bioinformatics*. 2015 Mar 15;31(6):948–56.

39. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017 Dec;42:60–88.
40. Hesamian MH, Jia W, He X, Kennedy P. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. *J Digit Imaging.* 2019; 29;32(4):582–96.
41. Cheng JZ, Ni D, Chou YH, Qin J, Tiu CM, Chang YC, et al. Computer-Aided Diagnosis with Deep Learning Architecture: Applications to Breast Lesions in US Images and Pulmonary Nodules in CT Scans. *Sci Rep.* 2016; 15;6(1):24454.
42. Shen D, Wu G, Suk HI. Deep Learning in Medical Image Analysis. *Annu Rev Biomed Eng.* 2017;21;19(1):221–48.
43. Ibtehaz N, Rahman MS. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks.* 2020;121:74–87.
44. M P, B Y, S S, M S. Cardiovascular Disease Prediction using Deep Learning. In: 2022 6th International Conference on Trends in Electronics and Informatics (ICOEI). IEEE; 2022. p. 1399–404.
45. Isensee F, Jaeger PF, Kohl SAA, Petersen J, Maier-Hein KH. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nat Methods.* 2021; 7;18(2):203–11.
46. Chen LC, Zhu Y, Papandreou G, Schroff F, Adam H. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. 2018; 7;
47. He K, Gkioxari G, Dollar P, Girshick R. Mask R-CNN. In: 2017 IEEE International Conference on Computer Vision (ICCV). IEEE; 2017. p. 2980–8.
48. Bansal S, A S, J MP, S M, Madisetty S, Rehman MZU, et al. A Comprehensive Survey of Mamba Architectures for Medical Image Analysis: Classification, Segmentation, Restoration and Beyond. 2024 Oct 3;
49. Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun ACM.* 2017; 24;60(6):84–90.
50. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. 2014 :4.
51. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. 2014;4.
52. Szegedy C, Wei Liu, Yangqing Jia, Sermanet P, Reed S, Anguelov D, et al. Going deeper with convolutions. In: 2015 IEEE Conference on Computer Vision and

- Pattern Recognition (CVPR). IEEE; 2015. p. 1–9.
53. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE; 2016. p. 770–8.
 54. Tan M, Le Q V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. 2019: 28.
 55. Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. 2020: 22
 56. Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, et al. Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. 2021: 25.
 57. World Health Organization. Global status report on noncommunicable diseases. World Heal Organ. 2010;53(9):1689–99.
 58. Shah PK. Mechanisms of plaque vulnerability and rupture. J Am Coll Cardiol [Internet]. 2003 Feb;41(4):S15–22.
 59. Easton JD, Saver JL, Albers GW, Alberts MJ, Chaturvedi S, Feldmann E, et al. Definition and Evaluation of Transient Ischemic Attack. Stroke. 2009 ;40(6):2276–93.
 60. Wolff T, Guirguis-Blake J, Miller T, Gillespie M, Harris R. Screening for Carotid Artery Stenosis: An Update of the Evidence for the U.S. Preventive Services Task Force. Ann Intern Med. 2007; 18;147(12):860–70.
 61. Rothwell P, Eliasziw M, Gutnikov S, Fox A, Taylor D, Mayberg M, et al. Analysis of pooled data from the randomised controlled trials of endarterectomy for symptomatic carotid stenosis. Lancet . 2003;361(9352):107–16.
 62. Selwaness M, van den Bouwhuijsen Q, Mattace-Raso FUS, Verwoert GC, Hofman A, Franco OH, et al. Arterial Stiffness Is Associated With Carotid Intraplaque Hemorrhage in the General Population. Arterioscler Thromb Vasc Biol . 2014 Apr;34(4):927–32.
 63. Gurm HS, Yadav JS, Fayad P, Katzen BT, Mishkel GJ, Bajwa TK, et al. Long-Term Results of Carotid Stenting versus Endarterectomy in High-Risk Patients. N Engl J Med . 2008 Apr 10;358(15):1572–9.
 64. Fel T, Felipe I, Linsley D, Serre T. Harmonizing the object recognition strategies of deep neural networks with humans. 2022; 8.
 65. Łukasiewicz S, Czeczelewski M, Forma A, Baj J, Sitarz R, Stanisławek A. Breast

- Cancer—Epidemiology, Risk Factors, Classification, Prognostic Markers, and Current Treatment Strategies—An Updated Review. *Cancers (Basel)* . 2021 Aug 25;13(17):4287.
66. So WKW, Law BMH, Ng MSN, He X, Chan DNS, Chan CWH, et al. Symptom clusters experienced by breast cancer patients at various treatment stages: A systematic review. *Cancer Med*. 2021; 21;10(8):2531–65.
 67. Chen H long, Zhou J qun, Chen Q, Deng Y chuan. Comparison of the sensitivity of mammography, ultrasound, magnetic resonance imaging and combinations of these imaging modalities for the detection of small (≤ 2 cm) breast cancer. *Medicine (Baltimore)* . 2021;2;100(26):e26531.
 68. Lu Y, Sun F, Wang J, Yu K. Automatic joint segmentation and classification of breast ultrasound images via multi-task learning with object contextual attention. *Front Oncol* . 2025;8;15.
 69. Breast ultrasound lesions recognition: end-to-end deep learning approaches. *J Med Imaging* . 2018;10;6(01):1.
 70. Xiong X, Zheng LW, Ding Y, Chen YF, Cai YW, Wang LP, et al. Breast cancer: pathogenesis and treatments. *Signal Transduct Target Ther* . 2025;19;10(1):49.
 71. Moccia S, De Momi E, El Hadji S, Mattos LS. Blood vessel segmentation algorithms — Review of methods, datasets and evaluation metrics. *Comput Methods Programs Biomed* . 2018;158:71–91.
 72. Vafaezadeh M, Behnam H, Gifani P. Ultrasound Image Analysis with Vision Transformers—Review. *Diagnostics* . 2024;14(5):542.
 73. Cao H, Wang Y, Chen J, Jiang D, Zhang X, Tian Q, et al. Swin-Unet: Unet-like Pure Transformer for Medical Image Segmentation. 2021;12
 74. Cao H, Wang Y, Chen J, Jiang D, Zhang X, Tian Q, et al. Swin-Unet: Unet-Like Pure Transformer for Medical Image Segmentation. In 2023. p. 205–18.

EKLER

EK-1. Özgeçmiş



EK-2. Etik Kurul Onayı

