

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**İSKEMİK İNMEİN MEDİKAL TARAMALAR ÜZERİNDE DERİN ÖĞRENME
YÖNTEMLERİ İLE TESPİTİ**

YÜKSEK LİSANS TEZİ

MERVE BALABAN

TEZ DANIŞMANI

DOÇ. DR. EMRE DANDIL

BİLECİK, 2024

10621752

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**İSKEMİK İNMEİN MEDİKAL TARAMALAR ÜZERİNDE DERİN ÖĞRENME
YÖNTEMLERİ İLE TESPİTİ**

YÜKSEK LİSANS TEZİ

MERVE BALABAN

TEZ DANIŞMANI

DOÇ. DR. EMRE DANDIL

BİLECİK, 2024

10621752

BEYAN

İskemik İnmenin Medikal Taramalar Üzerinde Derin Öğrenme Yöntemleri ile Tespiti adlı yüksek lisans tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	X
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:	/.....	

Öğrenci Adı ve Soyadı

Merve BALABAN

19/03/2024

.....
İmza

ÖN SÖZ

Bu tez, derin öğrenme yöntemlerinin tıbbi görüntüleme alanındaki önemli bir uygulaması olan MR (Manyetik Rezonans) görüntülerinden iskemik inme segmentasyonu üzerine odaklanmaktadır. İskemik inme, beyin dokusuna yeterli kan akışının sağlanamaması sonucu ortaya çıkan ciddi bir sağlık sorunudur ve doğru tanı ve tedavi süreci için hassas ve doğru bir segmentasyon gerekmektedir. Sürecin taşıdığı yaşam fonksiyonlarında veya yaşamsal faaliyetlerde kısıtlanma riski sebebiyle klinik değerlendirmenin hızlı yapılabilmesi de önem arz etmektedir. Bu nedenle tez çalışmamda, iskemik inme vakalarının tanı sürecindeki zaman ve doğruluk ihtiyacı üzerine derin öğrenme yöntemlerinin etkinliğini değerlendirmek ve mevcut yöntemleri geliştirmek için bir araştırma sunulmaktadır.

Bu çalışma, tamamlanması için birçok kişinin katkısını almıştır ve bu vesileyle birkaç kişiye teşekkür etmek isterim. İlk olarak, bu tezin gerçekleştirilmesindeki rehberliği, desteği ve yönlendirmeleri için danışmanım Doç. Dr. Emre DANDIL'a çok teşekkür ederim. Yine çalışma sürecindeki değerli katkılarından ötürü Arş. Gör. Dr. Gökhan UÇAR'a teşekkür ederim. Savunma sınavımda katkıları ve görüşleri ile tezimi son haline getirmeme yardımcı olan Doç. Dr. Süleyman UZUN ve Dr. Öğr. Üyesi Salim CEYHAN'a teşekkürlerimi sunarım.

Ayrıca, eğitim hayatımda bana ilham veren ve yol gösteren tüm öğretmenlerime teşekkür ederim. Bunun yanında, tez çalışmasında kullanılan verisetinin hazırlanmasında ve erişiminde emeği geçen ISLES'22 ekibine de teşekkürlerimi sunarım.

Ve, aileme, sevdiklerime sonsuz sabır, anlayış ve destekleri için teşekkürlerimi sunmak isterim. Bu süreçte yanımda olduğunuz, cesaretlendirdiğiniz ve inandığınız için teşekkür ederim.

Bu tez çalışması, vazgeçemeyişimin en özel nedeni abim Serkan'a ithaf edilmiştir. Teşekkürlerimle.

Merve BALABAN

2024

ÖZET

İSKEMİK İNMENİN MEDİKAL TARAMALAR ÜZERİNDE DERİN ÖĞRENME YÖNTEMLERİ İLE TESPİTİ

İnme, her yıl milyonlarca insanın hayatını kaybetmesine ve aynı zamanda kalıcı fiziksel ve bilişsel sorunlar yaşamasına sebep olan bir rahatsızlıktır. Beyindeki kan akışının ani kesintisi sonucu ortaya çıkmaktadır. İnme vakalarında semptomların görülmeye başlanıp hastaneye başvurulduğu dönem akut fazda teşhisin yapılması ve hemen tedaviye başlanması, hayati riski azalttığı gibi bireyin tedavi sonrası yaşam kalitesini iyileştirmek için de önemlidir. İnme lezyonlarının saptanması için uzman görüşünün yanı sıra, el yordamı ile bölütlemenin zaman alıcı bir süreç olması gereken hızlı teşhis ihtiyacını aksatmaktadır. İnme lezyonlarının bilgisayar destekli algoritmalar ile tespit edilmesi bu ihtiyaca uygun bir çözümdür. İnmede tedaviye geçiş sürecinde yaşanabilecek gecikmeler hastada fonksiyon kayıplarına ve ölüme sonuçlanabilecek beyin dokusunun ölmesine sebep olabilmektedir. Son yıllarda, derin öğrenme algoritmalarındaki gelişmeler, hastalıkların teşhis ve tedavisinde kullanılan medikal tarama analizinde klinik çözümlerin bir parçası olmaktadır. Yakın dönemde yapılan birçok çalışmada başarılı sonuçlar alınması, uzmanlara yardımcı olabilecek doğruluğu yüksek sistemler geliştirilmesi konusunda umut vaat etmektedir. Bu tez çalışmasında, iskemik inme vakalarında yaygın olarak kullanılan Manyetik Rezonans Görüntüleme (MRG) taramaları üzerinde lezyonların otomatik bölütlenmesini sağlamak amacıyla global açık bir verisetinde (ISLES'22) derin öğrenme yöntemlerinin etkisi incelenmektedir. Bölütleme görevinde derin öğrenme modellerinden U-Net mimarisi ile iki farklı evrimsel sinir ağının birleştirildiği yöntemlerin, difüzyon-ağırlıklı MR görüntüleri (DAG) üzerindeki performansları ölçülmüştür. Deneysel analizlerde, 250 hastaya ait MR görüntüleri ile eğitilen modeller kullanılarak F1-skoru, Dice benzerlik katsayısı ve Kesinlik (Precision), Duyarlılık (Recall) anahtar performans metrikleri için sırasıyla test kümesi üzerinde ortalama 0.85, 0.79, 0.86 ve 0.87 skorları başarılmıştır. Deneysel çalışma sonuçları, küçük boyut ve düzensiz şekiller nedeniyle zorlu inme lezyonlarına sahip ISLES'22 verisetinde katılımcılarının elde ettiği sonuçlarla örtüştüğü ve sonuç olarak U-Net ile oluşturulan modellerin, iskemik inme lezyonlarını başarılı bir şekilde bölütleme potansiyeline sahip olduğunu göstermiştir. Önerilen yöntemin klinik aşamalarda inme teşhisini kolaylaştıracağı ve karar verme sürecinde kullanılabilir bir yardımcı araç olabileceği değerlendirilmektedir.

Anahtar Kelimeler: İskemik İnme, Derin Öğrenme, Lezyon Tespiti, Otomatik Bölütleme, Difüzyon-Ağırlıklı MR, U-Net.

ABSTRACT

DETECTION OF ISCHEMIC STROKE ON MEDICAL SCANS USING DEEP LEARNING METHODS

Stroke is a public health problem that causes millions of people to lose their lives and experience permanent physical and cognitive problems every year. It occurs as a result of a sudden interruption of blood flow in the brain. Diagnosing stroke cases in the first period when symptoms begin to appear and applying to the hospital, that is, in the acute phase, and starting treatment as soon as possible is an important factor for improving the individual's quality of life after treatment, as well as reducing the life risk. In addition to the need for expert opinion to detect stroke lesions, the fact that manual segmentation is a time-consuming process hinders the need for rapid diagnosis in critical hours. Detection of stroke lesions with computer-aided algorithms is a suitable solution to this need. Delays in the transition to treatment in stroke may cause loss of function in the patient and death of brain tissue, which may result in death. In recent years, developments in deep learning algorithms have become part of clinical solutions in medical screening analysis used in the diagnosis and treatment of diseases. Successful results in many recent studies are promising for developing highly accurate systems that can assist experts. This thesis study examines the effect of deep learning methods on a publicly available dataset (ISLES'22) to provide automatic segmentation of lesions on Magnetic Resonance Imaging (MRI) scans, which are commonly used in ischemic stroke cases. In the segmentation task, the performance of the methods combining the U-Net architecture, one of the deep learning models, and two different convolutional neural networks was measured on diffusion-weighted MR images (DWI). In experimental analyses, average scores of 0.85, 0.79, 0.86 and 0.87 were achieved on the test set for the key performance metrics F1-score, Dice similarity coefficient and Precision and Recall, respectively, by using models trained with MR images of 250 patients. The experimental study results showed that they overlap with the results obtained by participants in the ISLES'22 dataset, which had challenging stroke lesions due to small size and irregular shapes, and as a result, the models created with U-Net have the potential to successfully segment ischemic stroke lesions. It is evaluated that the proposed method will facilitate the diagnosis of stroke in clinical stages and can be an assistant tool that can be used in the decision-making process.

Keywords: Ischemic Stroke, Deep Learning, Lesion Detection, Automatic Segmentation, Diffusion-Weighted MRI, U-Net.

İÇİNDEKİLER

ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iii
ŞEKİLLER LİSTESİ.....	v
TABLolar LİSTESİ.....	vii
SİMGELER VE KISALTMALAR DİZİNİ	viii
1. GİRİŞ.....	1
1.1. Tezin amacı ve Organizasyonu.....	4
1.2. Tezin Araştırma Sorusu ve Hipotez.....	4
2. LİTERATÜR TARAMASI	5
3. MATERYAL ve YÖNTEM.....	11
3.1. ISLES'22 Veriseti	12
3.2. Temel Bilgiler.....	14
3.2.1. U-Net.....	15
3.2.2. VGG19	18
3.2.3. ResNet50.....	19
3.2.4. Difüzyon Ağırlıklı (DAG) MR.....	21
3.3. Önerilen Model.....	23
4. DENEYSEL BULGULAR.....	26
4.1. Önerilen Yöntemlerin Karşılaştırması	36
5. TARTIŞMA	40
6. SONUÇLAR VE ÖNERİLER.....	42
KAYNAKÇA	44

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1. EDD Net ve Muscle Net mimarilerinin kullanıldığı çalışmada elde edilen segmentasyon sonuçları	6
Şekil 2.2. ISLES'15 veriseti üzerinde U-Net ile üretilen bölütleme aşamaları	8
Şekil 2.3. ISLES'15 verisetindeki FLAIR modalitesine ait farklı U-Net modellerinin bölütleme sonuçları.....	9
Şekil 2.4. BT görüntüleri ve Res2Net tabanlı U-Net modeli ile elde edilen segmentasyon maskeleri.....	10
Şekil 3.1. İskemik inme segmentasyonu için önerilen U-Net tabanlı hibrit derin öğrenme modellerinin genel görünümü.....	12
Şekil 3.2. ISLES'22 verisetinin farklı MR sekans görüntüleri ve anatomik düzlemlerdeki uzman etiketlemeleri örneği	13
Şekil 3.3. ISLES'22 Akut ve Sub-Akut İnmede Multimodal MR Enfarktüs Segmentasyonu verisetinden lezyon içeren örnek difüzyon MR (DAG) görüntüleri.....	13
Şekil 3.4. U-Net derin öğrenme mimarisinin tipik yapısı	17
Şekil 3.5. ImageNet için VGG-19 ağ mimarisi.....	18
Şekil 3.6. ImageNet için 34 parametre katmanına sahip artık ağ diyagramı	20
Şekil 3.7. Netron modülü ile üretilmiş standart ResNet50 modeli.	21
Şekil 3.8. Albach ve diğerlerinin çalışmasında sunduğu bir inme vakasına ait DAG ve FLAIR modaliteleri örneği	22
Şekil 3.9. Difüzyon ağırlıklı görüntüleme de dahil olmak üzere manyetik rezonans görüntüleme (MRG) kullanan 3 iskemik felç hastasından örnek taramalar	23
Şekil 3.10. Önerilen U-Net modeli diyagramı	24
Şekil 3.11. Netron ile üretilmiş U-Net+ResNet50 modeli diyagramı.....	25
Şekil 3.12. Netron ile üretilmiş U-Net+VGG19 modeli diyagramı.....	25
Şekil 4.1. ISLES'22 verisetine ait ADC ve DAG sekansından aynı hastanın ardışık MR kesitleri ve maskeleri	27
Şekil 4.2. Aynı hastaya ait sırasıyla MR başlangıç(üst) ve bitişine(alt) denk gelen görüntüler.....	33
Şekil 4.3. U-Net+ResNet50'e göre bazı ADC MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları.....	33

Şekil 4.4. U-Net+ResNet50'e göre bazı difüzyon MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları.....	34
Şekil 4.5. U-Net+ VGG19'e göre bazı difüzyon MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları.....	36
Şekil 4.6. Performans testlerinde başarıımı düşüren küçük boyutlu lezyonlar	38

TABLULAR LİSTESİ

	Sayfa
Tablo 4.1. Deneyde kullanılan bilgisayarın donanım özellikleri.....	26
Tablo 4.2. Önerilen U-Net modellerinin eğitim parametreleri ve değerleri.....	29
Tablo 4.3. ITK-SNAP ile el yordamı çıkartılan DAG kesitlerinin U-Net modeli için performans metriklerinin ortalamalarına göre sonuçları	32
Tablo 4.4. ResNet50 mimarisinin kullanıldığı U-Net modeli (U-Net+ ResNet50) için DAG taramalarının performans metriklerinin ortalamalarına göre sonuçları.....	32
Tablo 4.5. U-Net+ResNet50 mimarisinin kullanıldığı U-Net modeli için ADC görüntülerinin performans metriklerinin ortalamalarına göre sonuçları	34
Tablo 4.6. Veri setinde yapılan el yordamı ile yapılan ayıklama sonrası ResNet50 mimarisinin kullanıldığı U-Net+ResNet50 modeli için DAG taramalarının performans metrikleri ortalamalarına göre sonuçları	35
Tablo 4.7. Kodlayıcı olarak VGG19 mimarisinin kullanıldığı U-Net+ VGG19 modeli için performans metrikleri ortalamalarına göre sonuçları	35
Tablo 4.8. Önerilen U-Net modeli için kodlayıcı olarak kullanılan CNN mimarileri ve veri dağılımları	37
Tablo 4.9. Önerilen U-Net modelleri ile en yüksek başarıma sahip testlerin performans metriklerinin ortalamalarına göre sonuçları	37
Tablo 5.1. Literatürde ISLES'22 veriseti ile yapılan çalışmalar ve tez çalışmasının karşılaştırılması	40

SİMGELER VE KISALTMALAR DİZİNİ

2D : 2 Dimentional (2B)

3D : 3 Dimentional (3B)

ADC : Görünür Difüzyon Katsayısı (Apparent diffusion coefficient)

AI : Yapay Zeka (Artificial Intelligence)

ark. : arkadaşları

BT : Bilgisayarlı Tomografi (Computed Tomography)

CNN : Evrişimsel Sinir Ağları

CNN : Evrişimsel Sinir Ağları

CPU : Merkezi İşlem Birimi (Central Processing Unit)

DAG : Difüzyon Ağırlıklı Manyetik Rezonans Görüntüleme (Diffusion Weighted Imaging)

Dice : Dice Benzerlik Katsayısı (Dice Similarity Coefficient)

dk : dakika

DY : Duyarlılık (Recall)

DSA : Dijital substrat anjiyografi

FLAIR: Sıvı ile Zayıflatılmış Ters Çevirme İyileştirmesi (Fluid Attenuated Inversion Recovery)

FN : False Negative (Yanlış Negatif)

FP : False Positive (Yanlış Pozitif)

GPU : Grafik İşlem Birimi (Graphical Processing Unit)

HD-BET: Head and Neck Deep Learning Brain Extraction Tool

ILSVRC: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması

IoU : Birleşim Üzerinden Kesişme (Intersection over Union)

ISBI : International Symposium on Biomedical Imaging (Uluslararası Biyomedikal Görüntüleme Sempozyumu)

ISLES: İskemik İnme Lezyon Segmentasyonu (Ischemic Stroke Lesion Segmentation)

Jaccard: Jaccard Similarity Index

KS : Kesinlik (Precision)

MR : Manyetik Rezonans

MRG : Manyetik Rezonans Görüntüleme

MS : Multipl Skleroz (Multiple Sclerosis)

NifTI : Nörogörüntüleme Bilişim Teknolojisi Girişimi

PET-CT: Pozitron Emisyon Tomografisi (PET-BT)

ReLU : Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear Unit)

ResNet: Residual Network

sn : saniye

TN : True Negative (Doğru Negatif)

TP : True Positive (Doğru Pozitif)

U-Net : U-Şeklindeki Ağ Yapısı (U-Shaped Network)

VGG : Visual Geometry Group (Görsel Geometri Grubu)

X-ray : X-ışınları

1. GİRİŞ

Beyin, insan vücudunun en karmaşık ve hayati organlarından biri olmakla birlikte organlarımızın işleyişinde ciddi sorumluluk sahibidir ve insan olarak varlığımızın temelini oluşturur. Düşünme, duygulanma, hareket etme ve çevremizi algılama gibi temel yeteneklerimizin merkezidir. Beyin sağlığı, bedenimizin sağlıklı bir işleyişi sahip olması ve yaşam kalitemizin sürekliliği için göz ardı edilemez bir öneme sahiptir. Ancak, beyin sağlığıyla ilgili sorunlar aktif bir yaşam için gerekli fonksiyonlarımızı etkileyebilir ve hatta hayatımızı tehlikeye sokabilir. Beyin damar hastalıkları, dünya çapında milyonlarca insanı etkileyen önemli bir halk sağlığı sorunudur (Deuschl, G. vd. 2020; who.int 2023). Beyin sağlığını korumak ve hastalıkların riskini azaltmak için düzenli egzersiz yapmak, sağlıklı beslenmek, stresten kaçınmak ve sağlık kontrollerini ihmal etmemek önemlidir. Ayrıca, tütün ve alkol kullanımı gibi zararlı alışkanlıklardan kaçınmak da beyin sağlığını korumak için dikkat edilmesi gerekenlerdendir. Sağlıklı bir beyin, sağlıklı bir yaşamın temelidir ve toplumlarda beyin sağlığı konusundaki farkındalık artırılmalıdır. Beyin damarlarını etkileyen hastalıklar arasından inme, beyin kan damarlarının tıkanması veya yırtılması sonucu ortaya çıkan ve ciddi sonuçlar doğurabilen bir durumdur ve beyin damar hastalıkları arasında önde gelen bir tehdittir. İnme, kanser ve diyabet gibi ciddi hastalıkların ardından görülme sıklığı açısından üçüncü sırada yer alır (Feigin vd., 2021; Truelsen ve Bonita, 2008).

İnme, beyin dokusuna giden kan akışının kesilmesi veya azalması sonucunda ortaya çıkan ciddi bir sağlık sorunudur. Genellikle kan pıhtısı veya yağ birikmesi nedeniyle meydana gelen bu durum, etkilenen bölgedeki beyin hücrelerinin oksijen ve besin eksikliği nedeniyle ölmesine yol açmaktadır. İnme, etkilediği bölgeye ve ne kadar süre devam ettiğine bağlı olarak çeşitli belirtilere neden olabilir. Bunlar arasında düşünme becerilerinde zorlanma, unutkanlık, uzuvlarda güç kaybı veya uyuşma, konuşma güçlüğü ve görme sorunları gibi semptomlar görülebilmektedir. Ayrıca birçok risk faktörü, inme görülme olasılığını artırabilir; sağlıksız beslenme, kalp hastalıkları, diyabet, yüksek kolesterol ve tansiyon gibi damar sağlığını tehdit eden ve pıhtı oluşumuna ortam sağlayan durumlar örnek olarak gösterilebilecek ciddi etmenlerdendir (Yıldız vd., 2013).

Gelir düzeyi yüksek ülkelerde özellikle son yıllarda gelişen inme tedavileri ve rehabilitasyon süreçlerine bağlı olarak, ölümlerle sonuçlanan, yaşam kalitesini azaltan veya yaşam süresini kısaltan işlev bozukluklarında yaşanan azalmalar umut verici olmaktadır. Yaşanan gelişmelere rağmen, inme vakaları dünya genelinde ölüm ve sakatlık ile sonuçlanan ciddi bir sağlık sorunu olarak görülmeye devam etmektedir. Üstelik yüksek gelirli ülkelere

kıyasla düşük ve orta gelirli ülkelerde nüfus artışına bağlı olarak gelir dağılımında dengesizliklere özellikle inmeyi tetikleyebilecek diğer sağlık sorunlarının artışına ve dolayısıyla inme oranlarının artışına yol açtığı görülmektedir (Katan&Luft, 2018; Kim vd., 2019).

Ülkemizde her yıl yaklaşık 200.000 kişinin felç geçirdiği göz önünde bulundurulduğunda, inme, ölüm ve sakatlık ile sonuçlanan hastalıklar arasında önde gelen bir sağlık sorunu olmaktadır (Asil vd., 2011; Türk Börü vd., 2018; Köseoğlu Toksoy vd., 2018; Şenel vd., 2020) .

İnme, tıkalı arterlerden kaynaklanan iskemik inme ve damarın yırtılması veya patlaması sonucu kan sızıntısından kaynaklanan hemorajik inme olmak üzere iki kategoriye ayrılmaktadır. İskemik inme, toplumda hemorajik inmeye göre daha sık görülmektedir (Andersen vd., 2009; Dubey vd., 2013; Campbell vd,2019; Tsao vd., 2022).

İskemik inme, ölüm ve yaşamsal fonksiyonların kaybı ile sonuçlanabilecek tıbbi bir acil durumdur. İskemik inme vakaları için teşhis süresi oldukça kritiktir. Herhangi bir tedavi öncesi, uzman doktor muayenesi ve değerlendirmesi gereklidir. İnme durumunda tedaviye karar verme süreci önemlidir, tespitin bir an önce yapılması ve uygun tedaviye başlanmasının hayati riski ve fonksiyon kaybını en aza düşürmede etkili olduğu bilinmektedir (Vachha vd.,2015; Grau vd, 2001). Semptomların görülmesinden itibaren kliniklere başvurulması gerektiği gibi fiziki muayene, tıbbi görüntüleme veya laboratuvar testleri gibi yöntemlerle doğru teşhis ve zarar gören bölgenin belirlenmesi tedavi sürecini yönlendirmede etkilidir. Görüntüleme yöntemleri hasarlı dokuların ayırt edilmesini sağlaması bakımından teşhis sürecinde önemli bir konumdadır. Daha hızlı sonuçlar alınabildiği için tercih edilen Bilgisayarlı Tomografi (BT) yöntemi acil durumlarda kanamanın veya hasarın varlığından emin olmakta kullanılırken, Dijital substrat anjiyografi (DSA) veya manyetik rezonans anjiyografi (MRA) beyin damarlarının görüntülenmesi için kullanılmaktadır. Beyin dokusundaki hasarın bölgesel olarak belirlenmesini sağlayan Manyetik Rezonans Görüntüleme (MRG) yöntemi ise daha ayrıntılı bilgi edinmek için tercih edilmektedir.

İskemik inme bölütlemelerinde görüntüleme tekniklerinin avantajlarını tam olarak anlamak için, kullanılan tıbbi taramaların arkasındaki teknolojiyi anlamak önemlidir. Beyinde oluşabilecek hastalıkların teşhisinde kullanılan MRG, güçlü radyo dalgaları ve mıknatıslar kullanarak, beyin dokusunun detaylı bir görüntüsünü oluşturur. Özellikle iskemik inme vakalarının tespitinde etkili bir yöntem olarak kabul edilir. MR görüntüleri, diğer tıbbi görüntüleme tekniklerine göre daha yüksek kalitede görüntüler sunar ve zarar gören dokunun

konumu, şekli ve büyüklüğü gibi detayları daha net bir şekilde gösterir. Ancak, MR görüntülerinin yorumlanması ve analiz edilmesi zorlu ve zaman alıcı bir süreçtir. Uzmanlar, bazen detayları gözden kaçırabilir ve bu da aynı vakaya ait görüntülerin yorumları arasında radyologlar arasında farklılık göstermesine neden olabilir (Hoggard vd., 2001; Kloska vd., 2010; Vymazal vd., 2012).

Difüzyon Ağırlıklı (DAG) MRG yöntemi ile yapılan taramalarda özellikle iskemik inme durumlarında önemli bir rol oynadığı gözlemlenmektedir (Minematsu vd.,2003; Özsunar vd., 2003). Difüzyon MR olarak da bilinen bu yöntem, beyin dokusundaki mikro değişimleri gözlemlemeye odaklanmaktadır. Bu yöntem, beyin dokusundaki anormallikleri tespit etmek için su moleküllerinin difüzyon hızındaki değişimleri ölçebilme kabiliyetine sahiptir. Ayrıca, iskemik inmenin zarar verdiği dokunun bölgesel konumunu ve farklı evrelerini belirlemek, DAG yöntemi ile edinilen yüksek çözünürlüğe ve farklı kontrastlara sahip görüntülerden çıkarılan önemli bilgiler sayesinde büyük ölçüde kolaylaşmaktadır.

Gelişen teknoloji ile birlikte, iskemik inme vakalarının teşhis ve tedavisinde hızlı ve daha doğru sonuçlara ulaşmayı sağlayan yüksek teknolojik yöntemlerin kullanımı artmıştır (Ali vd., 2021). Özellikle son yıllarda, yapay zeka destekli tıbbi görüntü bölütleme yöntemleri, sağlık alanında önemli bir role sahiptir. Bu yöntemler sayesinde, iskemik inme vakalarının tespiti ve analizi daha kolay ve verimli hale gelmiştir. Derin öğrenme modelleri gibi yapay zeka teknikleri, bilgisayarlara insan beyninden esinlenerek verileri işleme yeteneği kazandırabilmektedir. Bu sayede, resimler, metinler, sesler ve diğer verilerdeki karmaşık modelleri tanıyarak doğru öngörü ve tahminler üretebilirler (Kamal vd., 2018; Karthik vd., 2020; Malik vd., 2024).

U-Net mimarisi, tıbbi görüntü bölütleme için geliştirilen derin öğrenme modellerinden biridir. Bu mimari, farklı seviyelerdeki özellikleri birleştirerek hassas bölütleme yeteneği sağlamaktadır. İnme vakalarının teşhisi için genellikle kontrastlı görüntüler içeren taramalar kullanılır ve bu taramaların detaylı bir analize ihtiyacı vardır, bu nedenle U-Net'in bölütleme işlemlerindeki hassasiyetinin etkili olması beklenmektedir. U-Net modeli, veri sayısının sınırlı olduğu durumlarda bile hızla öğrenme yeteneği göz önünde bulundurularak tasarlanmıştır (Zhou vd.,2018; Kadry vd., 2021; Ehab vd., 2023; Polat vd, 2023; Uçkun vd., 2023). İnme bölütlemesi gibi alanlarda, ulaşılabilir kaynakların sınırlı olması, araştırmacılar için U-Net'in tercih edilirliliğini artıran en etkili sebeplerdendir.

Bu tez çalışmasında, biyomedikal görüntü işlemede özelleştirilmiş derin öğrenme modellerinden U-Net'in MR görüntülerindeki iskemik inme lezyonlarının tespitinde kullanımı

incelenmiş ve analizleri yapılmıştır. Çalışma kapsamında, ISLES'22 Akut ve Sub-akut İnmede Multimodal MRG Enfarktüs Segmentasyonu veri setindeki iskemik hasarın en iyi gözlemlendiği DAG görüntüleri ile uzmanlar tarafından etiketlenmiş maske görüntüleri kullanılmıştır. Çalışma kapsamında evrişimli sinir ağı mimarilerinden ResNet50 ve VGG19 ile birleştirilmiş U-Net modelleri önerilmiş ve uygulama adımları anlatılmıştır. Tez çalışması sonucunda, kullanılan modellerden elde edilen sonuçların performans değerlendirmesi Dice benzerlik katsayısı (Dice), F1-skor (F1-score), duyarlılık (Recall), kesinlik (Precision) ve doğruluk (Accuracy) metriklerine göre yapılmıştır.

1.1. Tezin amacı ve Organizasyonu

Bu tezin amacı, farklı derin öğrenme mimarileri ile birleştirilmiş U-Net derin öğrenme mimarisi kullanılarak iskemik inme vakalarını içeren DAG MR taramaları üzerinde lezyon bölütlemelerini gerçekleştirmektir. Bunun için global açık bir veriseti olan ISLES'22 Akut ve sub-akut inmede multimodal MRG enfarktüs segmentasyonu veriseti üzerinde performans testleri yapılan ResNet50 ve VGG19 tabanlı U-Net derin öğrenme modelleri önerilmektedir.

Bu tez çalışmasının ilerleyen bölümlerinde, medikal taramalar üzerinde derin öğrenme yöntemleri ile iskemik inme tespitinin literatürdeki yerine değinilmiştir. Çalışmada kullanılan veri seti hakkında bilgilendirmeler yapılmış ve özelliklerine yer verilmiştir. Sonrasında, önerilen U-Net modellerinin mimarisi ve uygulamasından bahsedilmiştir. Sonuç bölümünde ise, çalışmada hedeflenen ve yapılan deneysel analizin bulgularına buna karşılık olarak elde edilen sonuçlara değinilirken yöntemin başarımı ve çalışmanın geleceği değerlendirilmiştir.

1.2. Tezin Araştırma Sorusu ve Hipotez

Bu tez kapsamında "Derin öğrenme yöntemleri, medikal tarama görüntülerinden iskemik inme lezyonlarının tespitinde geleneksel yöntemlere kıyasla daha yüksek doğrulukta sonuçlar sağlayabilir mi?" sorusundan yola çıkılarak önerilen U-Net mimarisinin global açık iskemik inme veriseti üzerinde yüksek performansa sahip olacağı hipotezi öne sürülmüş ve deneysel çalışmalar gerçekleştirilmiştir.

2. LİTERATÜR TARAMASI

Günümüzde, iskemik inme vakalarının tanı ve tedavisinde biyomedikal görüntüleme tekniklerinin kullanımı giderek artmaktadır. Tıbbi görüntüleme teknikleri arasında seçim yapmak intravenöz ve intraarteriyel iskemik inme (AIS) vakalarında tedaviye karar verme sürecinde önemli bir role sahiptir. İnmenin nedenini ve mekanizmasını ayırt etmede kullanılan Bilgisayarlı tomografi (BT) veya MRG teknikleri, beyin enfarktüsünün boyutunu ve arteriyel tıkanıklığı belirlemede yardımcı yöntemlerdir. Klinik uygulamalarda uzmanlar, BT/MR görüntüleme ile canlı beyin dokusu ve lezyonları daha rahat tanımlayabilmekte ve tedaviye daha hızlı geçebilmektedir. Son yıllarda, bu alandaki araştırmaların odak noktası, derin öğrenme yöntemlerinin MR taramaları üzerinde iskemik inme lezyonlarının doğru ve hassas bir şekilde segmentasyonunu gerçekleştirmek üzerine olmuştur. MR görüntüleme tekniklerinin gelişmesi ile özellikle Difüzyon MR taramalarının iskemik inme lezyonlarının erken dönem teşhisinde önemli bir rol oynamaktadır. Derin öğrenme modellerinin, özellikle de U-Net gibi özelleştirilmiş mimarilerin DAG taramalarından elde edilen verilerin analizi için kullanımı literatürde dikkat çeken çalışmalardan olmuştur.


İnme hastalığının teşhisi için literatürde daha önce birçok çalışma önerilmiştir. Bu literatür taraması ise, iskemik inme vakalarının teşhisi ve tedavisi için derin öğrenme yöntemlerinin MR görüntüleri üzerinde kullanılmasına odaklanmaktadır.

Vilela ve Rowley (Vilela ve Rowley, 2017), çalışmalarında tıbbi görüntüleme tekniklerinin beyin damarlarındaki dolaşımın ve pıhtı oluşumunun türü ve kapsamının belirlenmesindeki katkılarını karşılaştırmalı olarak değerlendirmektedir. Semptom görülen vakalarda sağlıklı ve lezyon oluşmuş dokunun ve alternatif arterlerdeki durumun ayırt edilebilmesi için gelişmiş inme BT ve MRG protokollerinin kullanıldığı ve böylece inme patofizyolojisi hakkında kesin bilgiler edinildiğine değinilmiştir. Çalışma boyunca yapılan değerlendirmeler ve literatür incelemeleri sonucunda DAG görüntülerinin lezyonların ve kollateral dolaşımın yetersizliği durumunda daha çok bilgi taşıdığı görülmüştür.

Zhu ve ark. (Zhu vd., 2021), akut iskemik inme tedavisinde uygulanabilecek mevcut tromboliz prosedürünün sınırlı süreyle yapılabilmesi dolayısıyla MRG taramalarında en çok bilginin alınabildiği DAG ve FLAIR (Fluid Attenuated Inversion Recovery) modalitelerini incelemişlerdir. Tromboliz tedavisinin inmenin başlangıcından geçen süreye bağlı olarak 4.5 saat veya daha kısa bir zaman içerisinde uygulanabildiği konusuna değinilmiştir. Zaman kısıtı sebebiyle vakaların tedaviden dışlanma ihtimalini azaltmak için hızlı ve yeterli bilgiye sahip sonuçlar alınabilecek yöntemlerin gerekliliği vurgulanmıştır. Çalışmada, DAG ve FLAIR

görüntülerinden inme lezyonlarının segmentasyonunu kısa sürede yapabilecek bir Evrişimsel Sinir Ağı (CNN) yöntemi geliştirilmiştir. Ancak, verisetinde gözlemlenen bazı yanlış pozitif (false positive) ve yanlış negatif (false negative) vakaların modaliteler arasındaki hiperintensite uyuşmaması nedeniyle, lezyon segmentasyon başarısızlıkları ile sonuçlandığı belirtilmiştir.

Chen ve ark. (Chen vd., 2017), çalışmalarında, akut iskemik lezyonların DAG görüntülerinden otomatik olarak bölütlemek için iki CNN içeren bir çerçeve önermişlerdir. EDD Net ve MUSCLE Net adlı iki CNN'nin birleşimi olarak geliştirilen yöntem kullanılarak, büyük bir klinik veri seti üzerinde test edilmiş ve 741 hasta verisinde ortalama Dice katsayısı ile başarılı bir lezyon tespit oranı elde edilmiştir. Çalışmaya ilişkin önerilen yöntemlere ait bölütleme testlerinin bir örneği Şekil 2.1.'de verilmiştir. Gelecekte, bu yöntemin geliştirilmesi için daha fazla DAG görüntüsü toplanarak eğitim ve test kümelerinin genişletilmesi ve çerçevenin geliştirilerek uçtan uca kullanıma uyarlanması önerilmiştir.



Şekil 2.1. EDD Net ve Muscle Net mimarilerinin kullanıldığı çalışmada elde edilen segmentasyon sonuçları

Kaynak: (Chen vd., 2017).

Cui ve ark. (Cui vd., 2022) yaptıkları iskemik inme tespiti için yapay zeka (AI) uygulamalarının kullanımının incelendiği çalışmada, yapay zeka çözümlerinin klinik


aşamaları kolaylaştırabileceği ve tedavi seçeneklerini artırabileceği öngörülmüştür. Yöntemin henüz doğruluğunun ve farklı zorluklar karşısında performansının yeterli olmadığı belirtilmiştir. Ayrıca uzman görüşü gibi bir yorumlama yeteneğinin olmayışının en büyük eksiklerden olduğuna değinilmiştir. Dolayısıyla yapay zeka çözümlerindeki tahmin yeteneğinin yanı sıra yorumlama yeteneğine de odaklanılması gerektiği sonucuna varılmıştır.

İskemik inme vakalarında lezyon tespiti için derin öğrenme yöntemlerinin geliştirildiği çalışmalar son yıllarda artış göstermiştir. Derin öğrenme modellerinin iskemik inme görüntülerinde performansının incelendiği bir tez çalışmasında, Altıntaş (Altıntaş, 2021), ISLES'18 verisetini kullanmıştır. Veriseti sağlıklı ve farklı inme türlerine ait beyin BT (Bilgisayarlı Tomografi) görüntülerini içermektedir. Veriseti testlerde kullanılmak üzere %80'i eğitim kümesi, %20'si test kümesi olacak şekilde ayrılmıştır. Çalışmada, AlexNet, ResNet, GoogleNet, InceptionV3, ShuffleNet ve SqueezeNet gibi transfer öğrenme yöntemi ile önceden eğitilmiş mimariler kullanılmıştır. Performans değerlendirmesi için beşli çapraz doğrulama (cross validation) tercih edilmiş ve en iyi sonuçlar AlexNet ile yapılan testlerde duyarlılık, kesinlik ve F1-skoru değerleri ölçülmüş ve başarılı sonuçlar elde edilmiştir. Sonuç olarak, çalışmada, modellerin yüksek doğruluğa sahip olduğunu ve inme vakalarının teşhisinde potansiyele sahip olduğu sonucuna varılmıştır.

Ronneberger ve ark. (Ronneberger vd., 2015) ise çalışmalarında medikal alanda kullanılmak üzere özelleştirilmiş U-Net modelini tanıtmışlardır. Bu model, sınırlı sayıda etiketlenmiş eğitim örnekleri ile etkili derin öğrenmeyi sağlamak amacıyla veri artırma stratejisine odaklanan bir sinir ağı ve eğitim yaklaşımına sahiptir. U-Net mimarisinde, bağlamı yakalamak için daralan bir yol ve simetrik genişleyen bir yol bulunmaktadır. Ağ, az sayıda görüntü ile eğitilmiştir, 2015 ISBI Challenge (International Symposium on Biomedical Imaging) yarışmasında elektron mikroskobu yığınlarında beyin hücrelerinin segmentasyonu için kullanılan kaydırmalı pencere konvolüsyon ağına göre daha başarılı sonuçlar üretilmiştir. Aynı ağ, ışık mikroskobu görüntüleriyle eğitildiğinde, 2015 ISBI hücre takip meydan okumasında büyük bir farkla birinci olmuştur. Yapılan testlerde ağın doğruluk başarısının yanında hız konusunda da başarılı sonuçlar elde ettiği görülmüştür. Buna örnek olarak, 512x512 bir görüntünün segmentasyonunun modern bir GPU (Graphical Processing Unit) üzerinde bir saniyeden az bir sürede tamamlandığı öne sürülmüştür.

U-Net modelini temel alan bir çalışmada Kadry ve ark. (Kadry vd., 2021), ISLES 2015 veri setinde bulunan beyin MR dilimlerinde iskemik inme lezyonlarının tespitine odaklanmışlardır. Segmentasyon için önceden eğitilmiş bir U-Net kodlayıcı-kod çözücü

sistemi kullanılmıştır. Çalışma kapsamında 20 hastanın görüntülerinden oluşan veriler ve çıkarılan lezyonların karşılaştırılmalı değerlendirmesi başarılı ölçümler elde edilmiştir. Şekil 2.2.'de çalışma kapsamında gerçekleştirilen test aşamalarına ve bölütleme sonucuna ait bir örnek verilmiştir. Önerilen şema, beyin anormalliklerini tespit etmede üstün doğruluk göstermiş, sorunun yeri ve ciddiyeti hakkında değerli bilgiler sağlamıştır.




Şekil 2.2. ISLES'15 veriseti üzerinde U-Net ile üretilen bölütleme aşamaları
Kaynak: (Kadry vd., 2021).

Derin öğrenme modellerinde U-Net ile ilerleyen gelişme sürecinin konu alındığı bir literatür incelemesinde Siddique ve ark. (Siddique vd., 2021), U-Net kullanılarak geliştirilen çeşitli uygulamalar ve görüntü yöntemlerini incelemiştir. Özellikle, medikal görüntü taramalarında kullanılmak üzere tasarlanmış U-Net mimarisinin farklı versiyonlarının BT taramaları, MRG, X-ışınları ve mikroskopi dahil olmak üzere çeşitli görüntü modalitelerinde başarılı sonuçlar elde ettiği incelenen çalışmalarda görülmüştür. Çalışmada 3D UNet, Attention U-Net, Inception U-Net, Residual U-Net, Recurrent U-Net, Dense U-Net, U-Net++, Adversarial U-Net ve Ensemble U-Net yaklaşımları ve literatürdeki örneklerine değinilmiştir. Ayrıca, U-Net modeli her ne kadar segmentasyon görevleri öncelikli olarak tasarlandıysa da başka alanlarda da verimli sonuçlar alabildiği de yine incelenen çalışmalardan yola çıkılarak belirtilmiştir.

Al Attar ve ark. (Al Attar vd., 2022), yaptıkları çalışmada beyin MRG taramalarında lezyon bölgelerinin segmentasyonunu gerçekleştirmek için CNN tabanlı bir yöntem önermektedir. ISLES'15 veri seti kullanılarak U-Net derin öğrenme modelinin inme lezyonlarının segmentasyonundaki performansı ve başarımları değerlendirilmiştir. ISLES'15 veriseti aksiyel, koronal ve sagittal düzlemdeki FLAIR modalitesine ait MR kesitlerinden oluşmaktadır. Acil tıbbi müdahale gerektiren iskemik inme vakalarında erken teşhis ve tedavinin kritik önemine değinilerek önerilen yöntemin klinik uygulamalarda yardımcı olacak düzeye ulaşması için iyileştirmeler yapılması vurgulanmıştır. Çalışmada önerilen yöntemle elde ettikleri segmentasyon sonuçları sırasıyla giriş görüntüsü, uzman etiketi ve bölütleme maskesi olarak Şekil 2.3.'te verilmiştir. Önerilen yaklaşımda temel U-Net, UNet+ ve UNet++ modelleri, 2D MRG taramalarında denendiği için 3D MRG

taramalarında kullanılmak üzere geliştirilmesi ve klinik uygulamalar için doğrulamalar yapılması gerektiği belirtilmiştir.



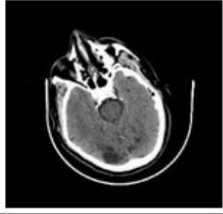
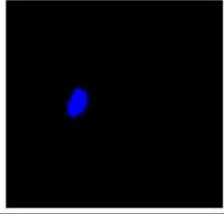
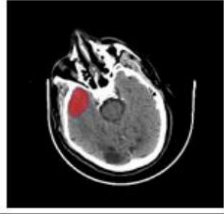
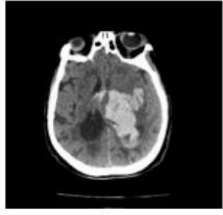

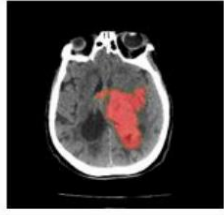
Şekil 2.3. ISLES'15 verisetindeki FLAIR modalitesine ait farklı U-Net modellerinin bölütleme sonuçları
Kaynak: (Al Attar vd., 2022).

Omarov ve ark. (Omarov vd., 2022), ISLES'18 veri seti üzerinde iskemik inme lezyonlarının bölütlenmesi için 3D UNet mimarisinin modifiye edilmiş bir versiyonunu kullanmışlardır. Çalışmalarında önerdikleri bu yeni model veri setinde eğitilmiş ve performansı Dice, F1-skoru ve Jaccard metriklerinde değerlendirilmiştir. Çalışmada kullanılan Modifiye 3D UNet modeli ile iskemik felci doğru bir şekilde bölümlere ayırmada standart 3D UNet modelinden daha yüksek bir benzerlik katsayısına ve duyarlılığa ulaşılmıştır. Modelin, eğitim verisi artırma, aşırı uyumu önlemek için bırakma ve düzenleme teknikleri gibi çeşitli yöntemler kullanılarak geliştirildiği belirtilmiştir.

Uçkun ve ark. (Uçkun vd., 2023) yaptıkları çalışma ile geliştirdikleri BrainSeg adlı yeni bir masaüstü uygulamasında kullandıkları yöntemleri ve performans değerlendirmeleri sunmuşlardır. BT görüntülerinden iskemik inme teşhisi yapabilmek için CNN kullanılmıştır. U-Net, U-Net VGG16, U-Net VGG19, Attention U-Net ve ResU-Net gibi CNN tabanlı mimarilerin, otomatik özellik çıkarma ve hastalık bölgelerini işaretlemedeki yetenekleri test edilmiştir. Çalışmada elde edilen en yüksek performans Modifiye ResU-Net mimarisinde ölçülmüş ve kolay kullanıma sahip olması için uygun bir arayüze sahip masaüstü uygulamasına entegre edilmiştir.

Yakın dönemde yapılan başka bir çalışmada ise Polat ve ark. (Polat vd., 2023), inme lezyonların tespiti ve segmentasyonu için önerdikleri modelde Res2Net omurgalı U-Net derin öğrenme modelini önermişlerdir. Çalışmalarında 1093 hemorajik ve 1130 iskemik inme vakasına ait görüntülemeler içeren bir veri seti kullanmışlardır. BT görüntülerinin ön işlem sürecinde pencereleme yöntemi tercih edilmiş ve sonrasında önerilen model ile eğitime tabi

tutulmuştur. Ön işlem yapılmış görüntülerde IoU (Intersection over Union) oranı daha yüksek olduğu görülürken görüntülerin veri çoğaltma ile artırılmasının ardından en yüksek IoU oranına ulaşılmıştır. Çalışmaya ait örnek bölütleme sonuçları Şekil 2.4.'te verilmiştir. Pencereleme yönteminde uygun ayarlamaların yapılması ile performansın artacağı öne sürülmüştür.

	Orijinal	Maske	Örtüşme
İskemik tip inme			
Hemorajik tip inme			

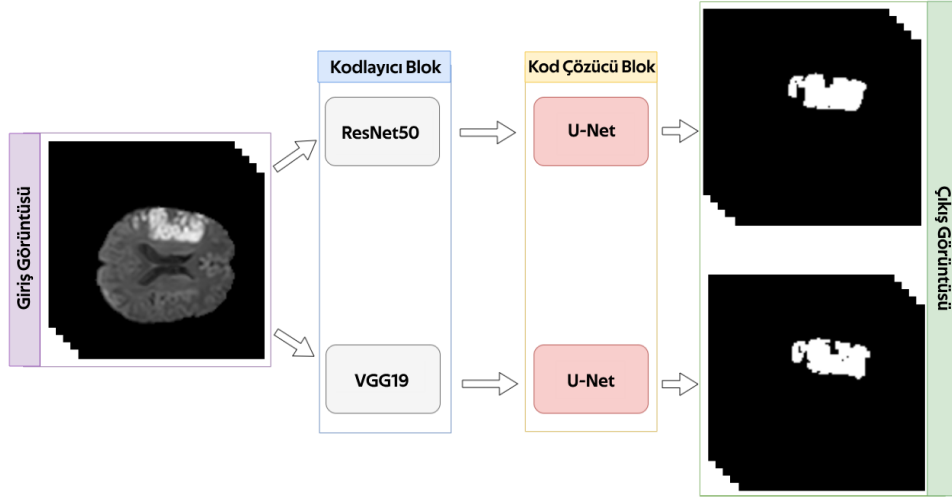
Şekil 2.4. BT görüntüleri ve Res2Net tabanlı U-Net modeli ile elde edilen segmentasyon maskeleri

Kaynak: (Polat vd., 2023).

3. MATERYAL ve YÖNTEM

Tıbbi görüntülemelerde bölütleme işlemi, tanı, tedavi planlaması ve hastalıkların izlenmesi için görüntünün anlamlı bilgiler çıkarılması için her biri farklı bir anatomik yapıya veya patolojik duruma karşılık gelen birden çok bölgeye ayrılmasıdır. Tıbbi görüntü segmentasyonunun bazı yaygın uygulamaları arasında tümör segmentasyonu, organ segmentasyonu, beyin lezyonu segmentasyonu ve damar segmentasyonu yer alır. Tıbbi görüntü bölütleme, manyetik MRG, BT, ultrason ve pozitron emisyon tomografisi (PET-BT) dahil olmak üzere çeşitli tıbbi görüntüleme modalitelerinde yaygın olarak kullanılmaktadır (Rogowska, 2000; Gezer, 2021). Tıbbi görüntülerin yüksek değişkenliği ve karmaşıklığının yanı sıra yüksek doğruluk ve sağlamlık ihtiyacı nedeniyle tıbbi görüntü segmentasyonu zorlu bir görevdir. Görüntü bölütleme yöntemleri eşikleme, bölge tabanlı bölütleme, sınır tabanlı bölütleme gibi geleneksel yöntemler, makine öğrenimi yöntemleri ve derin öğrenmeye dayalı yöntemler olarak gruplandırılmaktadır (Öztürk & Öztürk, 2018; Elen, 2020). Doğru görüntü bölütleme yöntemini seçmek, görüntünün türüne ve görevin gereksinimlerine bağlıdır ve istenen sonuçları elde etmek için birden çok yöntem birleştirilebilir. Son yıllarda, derin öğrenmeye dayalı yöntemler, tıbbi görüntü segmentasyonunda büyük umut vaat ederek, birçok çalışmada yüksek performans elde etmiştir. Bu yöntemler, tıbbi görüntülerin altında yatan kalıpları ve ilişkileri öğrenmek için yapay sinir ağlarını kullanır ve oldukça doğru segmentasyon sonuçları üretebilir. Ancak, eğitim verilerinin kalitesine ve çeşitliliğine göre değişkenlik gösterebilen, bu yöntemlerin performansını dikkatlice değerlendirmek önemlidir.

İskemik inme segmentasyonu için önerilen derin öğrenme modeli Şekil 3.1.'de gösterilmektedir. Tez çalışması kapsamında önerilen modeller, kafatası ayıklama işleminden geçirilmiş MR görüntüleri üzerinde uygulanarak iskemik inme lezyonunun bölütleme işlemi gerçekleştirilmektedir. Eğitim kümesi ile modellerin öğrenmesi gerçekleştirilmekte olup test kümesindeki görüntüler giriş görüntüsü olarak kullanılmaktadır. Model şeması U-Net modeli temel alınarak hazırlanmıştır. Geliştirilen iki modelin kodlayıcı bloğunda ResNet50 ve VGG19 algoritmaları kullanılmış ve kod çözücü blok ise U-Net algoritması olarak bırakılmıştır.



Şekil 3.1. İskemik inme segmentasyonu için önerilen U-Net tabanlı hibrit derin öğrenme modellerinin genel görünümü

3.1. ISLES'22 Veriseti

Bu tez çalışmasında, ISLES'22 İskemik İnme Lezyon Bölütleme Challenge kapsamında yayınlanan Akut ve Sub-akut İnmede Multimodal MRG Enfarktüs Segmentasyonu (Multimodal MRI Infarct Segmentation in Acute and Sub-Acute Stroke) alt görevi için yayınlanan veriseti kullanılmıştır. Kullanılan verisetindeki MR görüntüleri farklı kontrast ve lezyon boyutlarındaki 250 hastaya ait akut (0-7 gün) ve subakut (1-3 hafta) dönemdeki iskemik inme vakalarını içermektedir (Hernandez Petzsche vd., 2022). Veriseti, dahil edilen tüm vakalar için, FLAIR, DAG ve ADC (Apparent Diffusion Coefficient) olmak üzere üç MR sekansındaki görüntülerden ve DAG sekansından üretilmiş uzman etiketlemelerinden oluşmaktadır. Görüntüler, Nörogörüntüleme Bilişim Teknolojisi Girişimi (NifTI) formatında kaydedilmiştir. Önceki yıllarda yarışma kapsamında yayınlanan veri setlerine kıyasla yaklaşık 3 kat daha fazla sayıda tarama görüntüsüne ve kontrast, boyut, çoklu lezyon, erken dönem, ileri dönem gibi farklılıklar içeren görüntü çeşitliliğine sahiptir. MR görüntülerine, sadece baş ve boyun bölgesini bölütlemeye kullanılan HD-BET (Head and Neck Deep Learning Brain Extraction Tool) (Isensee vd., 2019) derin öğrenme modeli uygulanmıştır. Kafatası soyma işlemi dışında hiçbir ön işleme yapılmayarak araştırmacıların klinik açıdan daha fazla uygulanabilir yöntemler geliştirebilmesi adına verilerin mümkün olduğunca ham halinde kalması amaçlanmıştır. ISLES'22 verisetinde yayınlanan görüntülerin bahsi geçen MRG modalitelerindeki örnekleri ve uzman tarafından işaretlenmiş örneği Şekil 3.2.'de verilmiştir. Verisetinde kullanılan her bir vakaya ait taramalar DAG ve ADC


sekansları için aksiyel düzlemde 72, sagittal ve koronal düzlemde 112; FLAIR sekansında aksiyel düzlemde 352, sagittal düzlemde 281, koronal düzlemde 352 MR dilimine sahiptir.



Şekil 3.2. ISLES'22 verisetinin farklı MR sekans görüntüleri ve anatomik düzlemlerdeki uzman etiketlemeleri örneği

Kaynak: (Hernandez Petzsche vd., 2022).

Verisetinden maske çıkarımı işlemleri için yarışmada hazırlanan İnsan-Algorithm modeli kullanılmıştır. Modele göre, öncelikle MR görüntüleri üzerinde önceden Münih Üniversitesi Hastanesi'nin sağladığı verilerle eğitilmiş bölütleme algoritması uygulanmıştır. Sonrasında uzmanlar tarafından bölütleme sonuçları değerlendirilmiştir. Bu tez çalışmasında, akut inme lezyonlarının bölütlenmesindeki erken aşamada belirtilerin görülebilmesi sayesinde bölütleme işlemlerinde sunduğu hassasiyet dolayısıyla kullanımı tercih edilen DAG sekansı üzerinde etiketleme işlemleri gerçekleştirilmiş olup DAG sekansı için örnek görüntüler Şekil 3.3.'te verilmiştir.



Şekil 3.3. ISLES'22 Akut ve Sub-Akut İnmede Multimodal MR Enfarktüs Segmentasyonu verisetinden lezyon içeren örnek difüzyon MR (DAG) görüntüleri

3.2. Temel Bilgiler

Yapay zekâ, günümüzde geniş veri setlerine dayanarak edindiği mevcut bilgiyi insan beynine benzer işlemlerden geçirerek karar verecek hatta tahminde bulunacak konuma gelmiş olsa da Alan Turing'in 1950'li yıllarda makinelerin düşünebilmesi fikrini ortaya koymasıyla birlikte literatürde yer edinmeye başlamıştır (Turing, 1950). Devam eden yıllarda, John McCarthy, bilgisayarların basit davranışların ötesinde zekaya sahip olma potansiyeline odaklanan bir grup kurarak, makinelerin öğrenmeyi öğrenebileceği, zekanın makineye kendi dilinde tanımlanabileceği konusuna odaklanan bir çalıştay gerçekleştirilmiştir (McCarthy, 1968; McCarthy, 1983). Çalıştayda, makinelerin ince düşünülmüş, ayrıntılı tanımlamalar sayesinde insan dilini kullanmada ve sorun çözmede insani değerlendirme süreçlerine ulaşması amaçlanmıştır. Yapay zeka teriminin kullanılmaya başlandığı o dönemde, Cahit Arf yılında, Atatürk Üniversitesi'nde yaptığı konuşmada verdiği örnekler ile tek bir probleme odaklanan basit makinelerden yola çıkarak makinelerin daha karmaşık işlevleri öğrenebileceğini savunurken, mantıksal işlemlere dayandırılarak analitik düşünme becerisini edinebileceğini örnek makine tasarımı ile de göstermiştir (Arf, 1959). Sonraki yıllarda yapay zeka, araştırmacıların çeşitli algoritmaları, teknikleri ve uygulamaları keşfetmesiyle yeteneklerini geliştirmeye ve genişletmeye devam etmiştir. Örneğin, Semantik Ağlar ve Uzman Sistemler, bilgiyi temsil etmeyi ve bu bilgiye dayanarak akıllı kararlar almayı amaçlayan ilk yapay zeka sistemleri olarak geliştirilmiştir (Cockburn vd., 2019). Sonrasında bu gelişmeler, satranç oynayabilme gibi belirli görevleri gerçekleştirebilmek için insan zekasını taklit edebilen Zayıf Yapay Zeka sistemleri ve farklı alanlardaki bilgileri anlama, öğrenme ve uygulama kapasitesi olan sürücüsüz araçlar veya doğal dil işleme gibi becerilere sahip makineler geliştirmeye odaklanan Güçlü Yapay Zeka sistemleri ile devam etmiştir (Flowers, 2019).

1980'li yıllarda yapay zekada önemli adımların atıldığı Bağlam Tabanlı Yapay Zeka ile, akıllı asistan gibi çeşitli uygulamalarda umut vaat eden ilerlemeler sağlanmıştır. Bir diğer alan olarak Yapay Sinir Ağları, biyolojik sinir ağlarını taklit ederek öğrenme ve sınıflandırma yeteneği edinmesi sayesinde karmaşık verileri işleyebilen sistemlerin geliştirilmesini mümkün kılmıştır. 1950'lerden itibaren yapay zekanın katettiği ilerlemelerin, günümüzde Derin Öğrenme ve Evrişimli Sinir Ağları üzerinde yoğunlaştığı görülmektedir (Buchanan, 2005; Grace vd., 2018; West, 2018).

Derin öğrenme yöntemleri, karmaşık verisetlerinden öğrenme yeteneğine sahip derin sinir ağlarından oluşmaktadır. Derin öğrenme ile makineler karmaşık kalıpları çözme ve

kapsamlı veri kümelerine dayanarak bilinçli kararlar verebilme yetisine sahip olabilmektedir. Makine öğreniminin bir alt kümesi olan derin öğrenme, verileri işlemek ve analiz etmek için birden fazla katmana sahip yapay sinir ağlarının eğitilmesini gerektirmektedir. Yapay zeka alanı, araştırmacıların sürekli olarak çeşitli algoritmaları, teknikleri ve uygulamaları keşfetmesiyle yıllar içinde önemli bir evrime tanık olmuştur. Derin öğrenme, karmaşık kalıpları işleme ve analiz etme becerisiyle, yapay zekanın devam eden büyümesinde ve ilerlemesinde önemli bir araç olmaktadır (Cioffi vd., 2019). Görüntü segmentasyonu, nesne tanıma ve tıbbi görüntü analizi gibi hassasiyete ihtiyaç duyan görevlerde büyük başarılar elde etmiştir. Özellikle, U-Net gibi özel mimarilere dayalı derin öğrenme modelleri, görüntü segmentasyonu gibi zorlu görevlerde kullanılarak, tıbbi görüntülerde organların veya lezyonların yüksek doğrulukla sınıflandırılmasına ve konumlarının belirlenmesine olanak tanımaktadır. Böylece, hastalıkların erken teşhisi ve tedavisi gibi kritik durumlarda etkili sonuçlar alınabilmektedir.

3.2.1. U-Net


U-Net modeli, 2015 yılında Olaf Ronneberger, Phillip Fischer ve Thomas Brox tarafından semantik segmentasyon sorunlarından özellikle medikal görüntü segmentasyonu gibi görevler için geliştirilen bir derin öğrenme mimarisidir (Ronneberger vd., 2015). Semantik segmentasyonda giriş görüntüsündeki her bir piksel temsil ettiği bilgiye göre bir sınıfa dahil edilir, bu şekilde yüksek çözünürlükte bir görüntü elde edilebilir. Geleneksel yaklaşımların yanı sıra derin evrişimli sinir ağları, kenarları ayırt etme veya nokta tespiti gibi işlemlerin ötesinde daha karmaşık yapıların bölütlenmesine imkan tanımaktadır. Derin öğrenme modellerini eğitmek için duyulan geniş veri seti ve kaynak ihtiyacı, U-Net'in sınırlı sayıda veri kullanarak dahi yüksek doğruluk elde edebilmesi ile aşılabilmektedir. Geniş veri setlerinin toparlanması özellikle biyomedikal görüntüler gibi erişim zorluğu ve verilerin etiketlenmesi için uzmanlık gerektiren alanlarda karşılaşılan zorluklardandır. Görüntü segmentasyonu problemlerinde kullanımı yaygınlaşan tam evrişimli sinir ağı modeli olan U-Net mimarisi, biyomedikal görüntüleme alanında da büyük ilgi görmüş ve birçok araştırmada yüksek başarımlar elde edilmiştir (Li vd., 2023). Diğer derin evrişimli sinir ağı mimarilerinde, giriş görüntüsünden ağ parametrelerinin sayısını azaltmak için boyutları küçülterek özellik çıkarımı yapılmakta ve sonrasında özellik haritalarından öğrenmeyi gerçekleştirerek giriş görüntüsünü yeniden boyutlandırılmaktadır. Girdi ve çıktı boyutlarının eşit olduğu bu mimarilerin en büyük sorunu ise giriş görüntüsüne uygulanan doğrusal fonksiyonlar sebebiyle özellik aktarımında kayıpların yaşanmasıdır. U-Net ile

önerilen yaklaşımda, bu sorunun çözümüne yönelik dekonvolüsyon işlemleri kod çözücü blokta yapılması özellik kaybını da engellemektedir.

U-Net algoritması, kodlayıcı ve kod çözücü blokların darboğaz/köprü ile birbirine bağlandığı U şekline benzeyen bir yapıya sahiptir. Kodlayıcı blok (encoder) giriş görüntüsünden özellik çıkarımı işlemlerini gerçekleştirdiği için daralan yol, kod çözücü blok (decoder) ise özellik haritalarını yeniden orjinal boyuta döndürdüğü için genişleyen yol olarak da bilinmektedir. U-Net mimarisinde yer alan her bir blok, giriş görüntüsünün bölütlenmesinde farklı amaçları gerçekleştirmek üzere tasarlanmıştır (Azad vd., 2022).

Kodlayıcı blokta yer alan evrişimli bloklar (convolutional block) segmentasyona tabi tutulan giriş görüntüsünden alt örnekleme (down-sampling) yapılarak hiyerarşik özellikleri içeren özellik haritalarının oluşturulmasından sorumludur (Du vd., 2020). Evrişimli blokların her biri içerdiği aktivasyon katmanında ağı karmaşık ilişkilerini öğrenmesine imkan sağlamak için ReLU fonksiyonunu kullanarak ağı doğrusal olmasını engellemektedir. Ağ genelinde sigmoid aktivasyonunun uygulandığı çıkış katmanı haricinde piksel bazında ikili tahminler üretmek amacıyla ReLU aktivasyonu kullanılmaktadır. Ayrıca bloklar, çıkarılan her bir özelliğin belirli bir ortalama ve varyansa sahip olmasını sağlayan batch normalizasyon katmanını içermektedir. Batch normalizasyon işlemi ile ağı daha kararlı ve hızlı bir şekilde öğrenmesi sağlanmaktadır.

Evrişimli bloklardan sonra maksimum-havuzlama (max-pooling) aşaması bulunmaktadır. Bu aşamada, örneklerdeki uzamsal boyutları küçültmek için her bir bölgenin en büyük değeri seçilir ve örüntüler belirginleşmiş olur. Bu sayede daha fazla özellik çıkarılabildiği için ağı hesaplama maliyeti azaltılırken aynı zamanda ağı öğrenme kapasitesinde de artış elde edilir. Daralan yol boyunca, evrişimli bloklar ile daha fazla ayrıntı içeren özelliklerin çıkarılması ağı karmaşıklığını artırırken, maksimum-havuzlama aşaması özelliklerin öğrenilmesini kolaylaştırmakta ve böylece iki katmanın uyumu ağı daha verimli çalışmasını mümkün kılmaktadır. U-Net derin öğrenme mimarisinin tipik yapısı Şekil 3.4.'te görülmektedir.




Şekil 3.4. U-Net derin öğrenme mimarisinin tipik yapısı
Kaynak: (Ronneberger vd., 2015).

Kodlayıcı ve kod çözücü bloklar arasında köprü görevi görerek iki bloğu birbirine bağlayan darboğaz/köprü, daralan yolun çıkışından elde edilen özellik haritalarından en soyut özelliklerin yakalanmasını sağlamaktadır. Bu aşamada, kodlayıcı bloktan elde edilen özellik haritalarındaki anlamlı bilgiler içeren soyut özellikler kompakt bir şekilde kod çözücü bloğa aktarılır ve görüntünün yeniden boyutlandırılarak istenen çıktının elde edilmesi için işlem tabi tutulur. Ağ hesaplamasında maliyeti azaltarak kısıtlı kaynaklar ile eğitimin başarılmasını sağlayan darboğaz/köprü bloğunda gerçekleştirilen işlemler özellik haritalarının boyutsallığını azaltarak kritik özelliklerin korunmasını amaçlamaktadır.

Darboğaz/köprü aşamasının ardından U-Net mimarisinin simetrik yapısını tamamlayan kod çözücü blok gelmektedir. Kodlayıcı bloğa karşılık olarak kod çözücü blokta, alınan özellik haritaları genişletilerek ve detaylandırılarak çıkış görüntüsünün giriş görüntüsü boyutlarına ulaşması için yukarı örneklemelerden (up-sampling) geçirilir. Kod çözücü blok boyunca giriştekine yakın çözünürlüğe sahip bir segmentasyon haritası elde edebilmek için her blokta transpoz evrişim (transpose convolution) ve birleştirme (concatenation) işlemleri uygulanır. Transpoz evrişim katmanları, özellik haritalarını yeniden boyutlandıran, birleştirme katmanları ise kodlayıcı bloğun aynı seviyesinden gelen özellik haritaları ile birleştirme sağlayan işlemler içermektedir. Ayrıca kod çözücü bloklar, batch normalizasyonu ve ReLU aktivasyonuna sahip iki evrişimli katmana sahiptir. U-Net mimarisinin çıkış katmanında ise, sigmoid aktivasyon fonksiyonuna sahip 1x1 evrişimli katman kullanılarak segmentasyon maskesini üretilmektedir.

3.2.2. VGG19

Evrişimli katmanlar (convolutional layers) ve tam bağlantılı katmanlarından (fully connected layers) oluşan ve Şekil 3.5.'te görülen 19 katmanlı bir yapıya sahip VGG19, Visual Geometry Group (Görsel Geometri Grubu) tarafından geliştirilen bir evrişimli sinir ağı modelidir (Simonyan ve Zisserman, 2014). Görüntü tanıma görevlerinde yaygın olarak kullanılan 19 katmandan oluşan bu mimari, 16 evrişimli katman ve 3 tam bağlantılı katman içerir. Evrişimli katmanlarda giriş görüntüsüne 3x3 boyutunda filtreler uygulanarak özellik haritaları çıkarılırken, maksimum-havuzlama katmanları 2x2 filtreler ile pencere içinden en büyük değeri seçerek özellik haritalarını küçültürler ve bu sayede ağın hesaplama maliyetini azaltmaktadırlar. Ağın karmaşık özellikleri öğrenebileceği çok sayıda parametreye sahip olması evrişim ve aktivasyon katmanlarının birlikte ve art arda kullanılarak ağın derinleştirilmesi sayesinde mümkündür. Evrişimli katmanlar arasında bulunan maksimum havuzlama katmanları, özellik haritalarını küçültür ve parametre sayısını azaltarak özetlenmiş özellikler elde etmek için kullanılır. Bu katmanlar, özellik haritalarının boyutunu azaltarak ve öğrenilebilir parametre sayısını azaltarak özetlenmiş özellikler elde ederler. Basitliği ve etkinliği ile bilinen VGG19, nesne algılama, yüz tanıma ve içerik tabanlı görüntü alma gibi çeşitli uygulamalarda kullanılmaktadır (Mascarenhas&Agarwal, 2021).



Şekil 3.5. ImageNet için VGG-19 ağ mimarisi.

Kaynak: (Simonyan ve Zisserman, 2014).

VGG19 modelinde aktivasyon fonksiyonu olarak matematiksel karşılığı Eşitlik(3.1)'de gösterilen derin öğrenme modellerinde hesaplama kolaylığı açısından sıkça kullanılan ReLU (Rectified Linear Unit) (LeCun vd., 2015) tercih edilmektedir.

$$f(x) = \max(0, x) \quad (3.1)$$

Derin sinir ağlarının eğitimi sırasında, ReLU aktivasyon fonksiyonu sigmoid ve tanh gibi fonksiyonlara göre daha az problemle karşılaşır, çünkü gradyanların tükenmesi veya sıkışma gibi sorunlarla nadiren karşılaşır. Ancak, ReLU fonksiyonunun negatif bölgesinde türevi sıfır olduğu için bazı nöronlar "dökülme" sorunuyla karşılaşabilir, yani aktive olmazlar

ve öğrenmeyi durdururlar. Bu sorunu çözmek için aşırı uyumu (overfitting) azaltmada etkili bir yöntem olan Leaky ReLU gibi geliştirilmiş versiyonlar kullanılabilir. Leaky ReLU (Leaky Rectified Linear Unit), negatif değerler için belirli bir eğim (slope) kazanılmasını sağlar ve böylece negatif bölgede sıfır türev yerine bir türev elde edilmesine imkan verir. Leaky ReLU fonksiyonu matematiksel olarak Eşitlik (3.2)'de gösterildiği gibi uygulanmaktadır. Denklemden kullanılan eğim parametresi (a), ağıın performansına ve veri setine bağlı olarak genellikle 0 ile 1 arasında seçilir ve negatif bölgedeki eğimin sadece bir miktar artması istendiği için çok küçük olmalıdır. Örneğin, 0.01 değeri yaygın olarak tercih edilmektedir (Sharma, 2019).

$$f(x) = \begin{cases} x, & \text{eğer } x > 0; \\ ax, & \text{eğer } x \leq 0 \end{cases} \quad (3.2)$$

Evrişimli katmanların ardından, özelliklerin sınıflandırılmasını gerçekleştiren tam bağlantılı (fully connected) katmanlar gelmektedir. Evrişimli katmanlarda aktivasyon fonksiyonu olarak ReLU kullanılırken, tam bağlantılı katmanlarda ise çoklu sınıf sınıflandırma problemlerinde sınıflar arasında dağılımı olasılık olarak ifade edebilen softmax fonksiyonu sıklıkla tercih edilmektedir. Softmax aktivasyon fonksiyonunda vektörlerin her bir elemanı 0 ile 1 arasında bir olasılık değerine dönüştürülür ve bu olasılıkların toplamı 1'e eşittir. Bu nedenle, softmax fonksiyonu sınıflar arasında bir olasılık dağılımı oluşturur. Softmax fonksiyonu, x_i bir vektörün i 'inci elemanını, N toplam sınıf sayısını, e ise Euler sayısına karşılık gelecek şekilde genellikle matematiksel olarak, Eşitlik(3.3)'teki gibi tanımlanmaktadır (Franke&Degen, 2023).


$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad (3.3)$$

VGG19, ImageNet veri kümesi gibi büyük ve çeşitli veri setlerinde eğitilmiştir ve genel nesne tanıma görevlerinde oldukça başarılı sonuçlar elde edebilmektedir. Ayrıca, transfer öğrenme yöntemleriyle, VGG19'un önceden eğitilmiş ağı, daha küçük veri setleri üzerinde spesifik görevler için de kullanılabilir.

3.2.3. ResNet50

ResNet (Residual Network), 2015 yılında Microsoft araştırmacıları tarafından geliştirilen görüntü tanıma görevleri için yaygın olarak kullanılan derin evrişimli sinir ağı mimarilerindedir (He vd., 2016). VGG19 mimarisinden esinlenerek hazırlanan mimari, ILSVRC-2015 (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması) sınıflandırma görevinde birinci olmuştur. Nesne algılama, yüz tanıma ve semantik segmentasyon gibi çeşitli

uygulamalarda kullanılmaktadır. Derin sinir ağlarında eğitim sırasında performansın düşük olması veya geriye doğru yayılan gradyanların kaybolması ile oluşan aşırı derinlik sorununu çözmek için tasarlanan ResNet, bu sorunu aşmak için katmanlar arasına paralel bağlantılar ekleyerek bir atlamalı bağlantı (skip connection) yapısı kullanmaktadır. Şekil 3.6.'da görüldüğü gibi, ResNet mimarisinin temelinde atlamalı bağlantılarla birbirine bağlı olan bir dizi evrişimli katmanın bulunduğu blok yapısı yer almaktadır. Bu atlamalı bağlantılar, ağ derinliği arttıkça gradyanların geriye doğru yayılmasını sağlamak için blokların giriş ve çıkışını doğrudan birbirine bağlar. ResNet, bu blok yapısını tekrarlı bir düzende kullanarak derin ağlar oluşturma potansiyeli sunmaktadır.




Şekil 3.6. ImageNet için 34 parametre katmanına sahip artık ağ diyagramı

Kaynak: (He vd., 2016).

ResNet mimarisinden üretilen ResNet50 mimarisi, evrişimli katmanlar, havuzlama katmanları ve tam bağlantılı katmanlar dahil olmak üzere 50 katmandan oluşmakta ve darboğaz blokları kullanılmaktadır. Girdi görüntüsünden özellikler çıkarmak için evrişim işlemlerinin uygulandığı evrişimli katmanlar arasında boyut azaltma işlemi için havuzlama katmanları bulunur. Bir katmanın çıktısını daha derin bir katmanın girişine doğrudan eklemeyi sağlayan atlamalı bağlantılar ağın derinliğine rağmen, eğitim sırasında gradyanların daha düzgün akmasını ve aşırı öğrenmenin azaltılmasını sağlamaktadır. Evrişimli katmanlarını takip eden tam bağlantılı katmanlar (fully connected layers), softmax aktivasyon fonksiyonunu kullanarak özellikleri sınıflandırmak için kullanılmaktadır (Sharma vd., 2023). ResNet50 modelinin açık kaynak erişimli Netron (Roeder, 2023) modülü ile oluşturulmuş diyagramı Şekil 3.7.'de verilmiştir.

ResNet'in farklı katman sayısına sahip alt modelleri genellikle bilgisayarlı görü, nesne tanıma ve diğer görüntü işleme görevlerinde kullanılır. ResNet'in derinliği arttıkça performansı genellikle iyileşmekle birlikte, derin modellerin eğitimi donanım özelliklerine de bağlı olarak zorlayıcı olabilmektedir. ResNet, derin sinir ağlarının tasarımında devrim niteliğinde bir adım olarak kabul edilir ve birçok görevde etkili bir şekilde kullanılmıştır.




Şekil 3.7. Netron modülü ile üretilmiş standart ResNet50 modeli.

ResNet mimarisinde, ağın temel haritalamasını doğrudan öğrenmek yerine artık bağlantılar kullanılmaktadır. Derin mimarilerin kullanımında bu yaklaşım ile performans büyük ölçüde artırılabilir. Ayrıca, ResNet'in önceden eğitilmiş ağırlıklara sahip olması, görüntü tanıma görevlerinde küçük veri setleriyle bile etkili doğruluğu yüksek sonuçlar alınmasına olanak tanır. ResNet50 modeli, bu özellikleriyle, derin öğrenme alanında önemli bir role sahiptir.

3.2.4. Difüzyon Ağırlıklı (DAG) MR

Dünya çapında yumuşak doku görüntülemeye yaygın olarak kullanılan beyin MRG, beyinde oluşan tümörlerin, inme, bunama ve multipl skleroz (MS) gibi kronik sinir sistemi hastalıklarını tespit etmek için ve anevrizmal kanama gibi nörolojik acil durumları teşhis etmek için başvurulan bir yöntemdir. Nörolojik vakalarda hastalığın teşhisi ve klinik tedavisinde belirleyici bir rol oynamaktadır (Fawzi vd., 2021). Acil müdahale gerektirebilecek durumlarda beyin MR taraması, uzmanların karar verme sürecinde kritik öneme sahiptir. Akut iskemik inme durumunda tedavi olarak damar içerisinde tıkanmalara sebep olan kan pıhtısının eritilerek kan akışının tekrar sağlanması için de gereklidir. Beyin MRG yönteminde yüksek çözünürlükte görüntülenebilen yumuşak dokular hakkında Beyin BT' sine göre kesit sayısının da fazla olması sayesinde daha ayrıntılı bilgiler edinilebilmektedir. Bunun yanı sıra radyasyon kullanılmaması gibi bir avantajı olmasına rağmen işlem süresinin uzunluğu, maliyet ve manyetik alana duyarlı tedavi öyküsüne sahip olan hastalar açısından dezavantajları da bulunmaktadır.


BT taramaları her ne kadar hızlı sonuçlar üretebilse de, Beyin MRG ve BT taramaları, kanama ve enfarktüs ayrımını yapabilecek hassasiyete iskemik inmenin başlangıcından 12-24 saat sonrasında ulaşabilmektedir. Tedaviye geçiş sürecinin kritik olduğu bu gibi vakalarda beyin damarlarında tıkanma yaşanan bölgenin yeri ve boyutunun yüksek doğrulukta görülmesi gerekmektedir. MRG alanında yaşanan ilerlemeler sayesinde geliştirilen Difüzyon ağırlıklı MRG (DAG) yöntemi, iskemik inme başlangıcından kısa süre içerisinde yüksek çözünürlükte, önemli bilgilerin alınabilmesini sağlayabilmektedir.



Şekil 3.8. Albach ve diğerlerinin çalışmasında sunduğu bir inme vakasına ait DAG ve FLAIR modaliteleri örneği
Kaynak: (Albach vd., 2013).

Yaygın bilinen kullanımı ile DAG, suyun difüzyon hareketine duyarlı bir yöntemdir ve bölgesel olarak suyun moleküler hareketinin azaldığı dokular DAG sekansında hiperintens olarak görülür (Hand vd., 2006). Albach ve ark. (Albach vd., 2013) yaptıkları çalışmada incelenen verilerden afazi belirtileri gösteren bir hastada, sol ve sağ orta serebral arter bölgelerinde DAG'da çok sayıda küçük hiperintensite görülmüştür. İlk hiperintensite, sağ kortikal alanda DAG'da belirmiş ve 2. gün sonrasında kaybolmuş ancak FLAIR'da görülmemiştir. 2. gün, DAG ve FLAIR'de yeni bir sol kortikal hiperintensite tespit edilmiştir (Albach vd., 2013). Çalışmaya ait görüntüler Şekil 3.8.'de verilmiştir.

Hobohm ve ark. ise (Hobohm vd., 2014) çalışmalarında inme semptomlarının başlamasından sonraki 3 saat içinde, sistemik tromboliz öncesi DAG ve FLAIR görüntüleme yöntemleri kullanmışlardır. Primer kanamayı dışlamak için tedavi öncesi MR görüntülemesi, BT ise 24 saat içinde gerçekleştirilmiştir. Tedavi sonrasında ise kanama tespiti için BT kullanılmıştır. Sistemik tromboliz öncesi FLAIR pozitif lezyonlar, tedaviye bağlı intraserebral kanama ile ilişkilendirilmiştir ve bu durum için 3 iskemik felç hastasından örnek taramalar Şekil 3.9.'da gösterilmektedir.



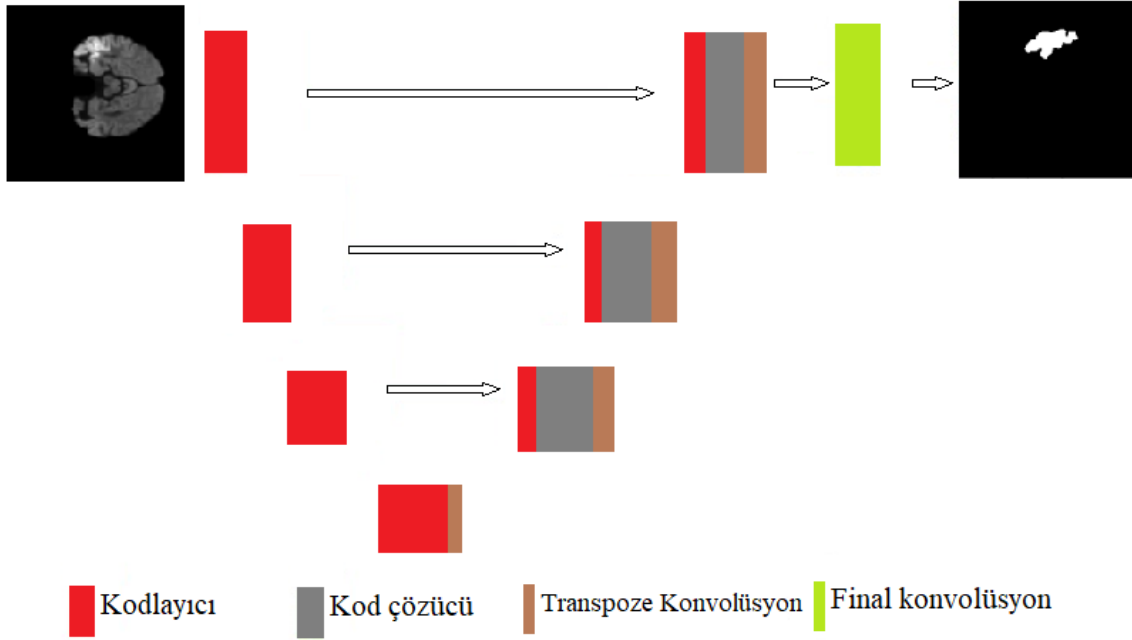
Şekil 3.9. Difüzyon ağırlıklı görüntüleme de dahil olmak üzere manyetik rezonans görüntüleme (MRG) kullanan 3 iskemik felç hastasından örnek taramalar
Kaynak: (Hobohm vd., 2014)

DAG, MRG sekansları arasında akut inme lezyonunun tanımlanmasında yüksek hassasiyet ve kesinliğe sahip sonuçlar üretmesi ile klinik bir standart haline gelmiştir. İskemik inme gibi hızlı müdahale gerektiren bir durumda DAG yöntemiyle semptomların başlamasından kısa süre içerisinde akut iskemik lezyonlar hakkında gerekli bulgular elde edilebilmektedir. Dolayısıyla bu yöntem, erken dönem iskemik inme vakalarında teşhis konulmasını ve tedaviye karar verilmesini uzmanlar açısından kolaylaştırmaktadır (Van Everdingen vd., 1998).

3.3. Önerilen Model

Bu tez çalışması kapsamında U-Net modeli ile yaygın kullanıma sahip iki farklı derin öğrenme mimarisi olan ResNet50 ve VGG19 birleştirilmiştir. Modellerin farklı mimarileri birleştirmesinde daha kapsamlı ve etkili bir görüntü segmentasyonu elde edilmesi amaçlanmaktadır. U-Net, özellikle tıbbi görüntüleme alanında sıkça kullanılan ve çok başarılı sonuçlar veren bir segmentasyon modelidir ve literatürde başarılı sonuçlar elde ettiği çalışmalar mevcuttur. Ancak sınırlı sayıda verisetlerinin elde edilebildiği biyomedikal görüntü segmentasyonu alanında tek başına U-Net mimarisi yerine özellikle özellik çıkarımında performansı artışı sağlamak amacıyla farklı avantajları olan iki farklı derin öğrenme mimarisiyle birleştirilmiştir. Bu yaklaşım, farklı görüntü segmentasyon görevleri için daha


esnek ve özelleştirilebilir bir çözüm sunma potansiyeline sahiptir ve tıbbi görüntüleme uygulamaları da dahil olmak üzere çeşitli alanlarda kullanılabileceği öngörülmektedir.



Şekil 3.10. Önerilen U-Net modeli diyagramı


Önerilen ilk modelde (U-Net+ResNet50), Şekil 3.10.'da gösterilen U-Net mimarisinin kodlayıcı kısmı ResNet50 ile değiştirilmiş ve daha derin bir ağ eğitme olanağı kazanılmıştır. Model, solda bir kodlayıcı blok ve sağda bir kod çözücü blok içeren U-Net mimarisi üzerinde geliştirilerek iki mimarinin de anlamlı bilgiler taşıyan özellikler çıkartabilme gücünden yararlanmayı hedeflemektedir. ResNet50 modeli, geniş bir nesne sınıflandırma veri seti olan ImageNet üzerinde önceden eğitilmiş ağırlıkları kullanır ve derin evrimsel katmanları, ayrıntılı ve anlamlı özelliklerin çıkarılmasına imkan tanır. Bu özellikler eklendiğinde, U-Net mimarisinin segmentasyon görevi için bilgi dolu bir temel sağlaması beklenmektedir. Özellikle kullanılan sınırlı veri seti üzerinde model eğitiminin verimliliğini artırması hedeflenmiştir. Önerilen modelde, U-Net mimarisinin bir parçası olarak görev yapan ResNet50, ağ içinde bir kodlayıcı olarak giriş görüntüsünden hiyerarşik özellikler çıkarmakla ve özellikleri kod çözücü bloğa aktarmakla sorumludur.

Derin öğrenme ve sinir ağları için görsel modelleme imkanı sunan Netron (Roeder, 2023) modülü ile üretilmiş U-Net+ResNet50 modeli diyagramı Şekil 3.11.'de verilmiştir.



Şekil 3.11. Netron ile üretilmiş U-Net+ResNet50 modeli diyagramı

Önerilen ikinci model (U-Net+VGG19), VGG19'un, U-Net mimarisinin kodlayıcı kısmında kullanıldığı U-Net ile VGG19'un birleştirilmiş bir mimarisini temsil etmektedir. Bu mimari, VGG19'un basit ve simetrik yapısından yararlanırken, U-Net'in güçlü segmentasyon yeteneklerini de içermektedir. VGG19, geniş veri setleriyle önceden eğitilmiş ağırlıklara sahip olduğundan, transfer öğrenme yöntemiyle daha küçük veri setleri üzerinde daha iyi özellik çıkarımı yapabilmektedir. Ayrıca, VGG19'un çok katmanlı ağ yapısı, giriş görüntüsünden farklı seviyelerde özellik haritaları çıkartabilme ve bu sayede segmentasyon performansını artırma potansiyeline sahiptir. Ağdaki evrişim katmanlarının küçük filtreler kullanması, etkili bir özellik öğrenme ortamı sunar ve katmanlarda değişiklik yapma esnekliği sağlar. Bu yaklaşım, VGG19'un özellik çıkarım yeteneklerini U-Net'in segmentasyon gücüyle birleştirerek daha etkili bir model oluşturmayı amaçlamaktadır. Netron ile üretilmiş U-Net+VGG19 modeli diyagramı Şekil 3.12.'de verilmiştir.



Şekil 3.12. Netron ile üretilmiş U-Net+VGG19 modeli diyagramı

4. DENEYSEL BULGULAR

Bu tez çalışmasında, MRG tarama verileri üzerinde iskemik inme segmentasyonunu U-Net modeli ile ResNet50 ve VGG19 modelleri birleştirilerek geliştirilen hibrit modeller kullanılarak gerçekleştirilebilen, segmentasyon işleminde verinin hazırlık aşamasını kolaylaştıran bir ortam geliştirilmiştir.

Tez çalışması kapsamında yapılan testler öncesinde verisetinin hazırlık aşamasındaki el yordamı ile yapılan işlemler kod blokları ile otomatikleştirilmiş ve süreç hızlandırılmıştır. Önerilen modellerde kullanılacak eğitim kümesi verisetinin %87'sini ve test kümesi %13'ünü kapsayacak şekilde bölünmüştür. Kümelerde rastgele atama işlemi yapılmaktadır. Ayrıca modeller eğitilmiş ve performans başarımları değerlendirilmiştir. Çalışmada önerilen modellerin eğitimi yaklaşık olarak 150 epok için 11 saat, 100 epok için 7 saat ve 50 epok için 2.5 saat sürmüştür.

Tez çalışmasında deneysel çalışmalar için kullanılan dizüstü bilgisayarın donanım özellikleri Tablo 4.1.'de verilmiştir.


Tablo 4.1. Deneyde kullanılan bilgisayarın donanım özellikleri

Donanım elemanı	Özellikler
İşlemci	12. Nesil Intel Alder Lake i7-12700H, 2.30 GHz (Turbo Boost: 4.70 GHz)
RAM	32 GB
Grafik kartı	6 GB Nvidia RTX3060
Yazılım dili	Python 3.11.4
Geliştirme Ortamı	Jupyter Notebook 6.5.4
Makine Öğrenimi Çerçevesi	Tensorflow Keras 2.10.0
CUDA Sürümü	Cuda compilation tools, release v11.2

Çalışma kapsamında kullanılan ISLES'22 veri seti bazı ön işlem süreçlerinden geçirildikten sonra eğitim, test setlerine bölünerek ağ içinde önerilen modellerin uygulanmasına hazır hale getirilmiştir. Yarışma kapsamında yayınlanan 250 vakaya ait MR taramaları çalışmaya dahil edilmiştir. FLAIR, ADC ve DAG sekanslarının yer aldığı verisetinden iskemik inme lezyonlarının atak geçirilmesinden hemen sonra ve erken dönem vakalarda da en iyi görüntülediği DAG sekansı tercih edilmiştir.

Su moleküllerinin hücreler arası nasıl hareket ettiğini gösteren DAG sekansından, bu hareketin yönünü ve miktarını ölçen ADC sekansındaki görüntüler elde edilmektedir. Bu

nedenle, sıklıkla birlikte kullanılan ADC ve DAG sekanslarına ait verisetinden örnekler Şekil 4.1.'de verilmiştir. İskemik inme lezyonları ADC sekansında düşük yoğunlukta (hipointens), DAG sekansında ise yüksek yoğunlukta (hiperintens) görülmektedir.



Şekil 4.1. ISLES'22 verisetine ait ADC ve DAG sekansından aynı hastanın ardışık MR kesitleri ve maskeleri

İskemik inme segmentasyonunu değerlendirmek için performans değerlendirme metriklerinden duyarlılık (recall), doğruluk (accuracy), F1-skor (F1-score), Dice benzerlik katsayısı (dice coefficient) ve kesinlik (precision) kullanılmıştır. Bu ölçümler; doğru pozitif (TP), yanlış pozitif (FP) ve yanlış negatif (FN) gibi iyi bilinen karmaşıklık matrisi parametreleri kullanılarak hesaplanmıştır ve sırasıyla Eşitlik (4.1), Eşitlik (4.2), Eşitlik (4.3), Eşitlik (4.4) ve Eşitlik (4.5)'te sunulmuştur.

Eşitlik (4.1)'de yer alan duyarlılık metriği, model tarafından yapılan tüm doğru pozitif tahminlerin gerçek pozitiflerin toplamına oranını ölçmektedir ve yanlış negatif tahminlerin fazla olması durumunda tercih edilmektedir. Eşitlik (4.2)'de yer alan doğruluk metriği, doğru tahminlerin (hem doğru pozitif hem de doğru negatif) tüm tahminlere oranını ölçer. Genel doğruluk düzeyini gösterir ancak bu durum dengesiz veri kümelerinde yanıltıcı olabilmektedir. Eşitlik (4.3)'te yer alan F1-skoru, kesinlik ve duyarlılık metriklerinin harmonik ortalamasını almaktadır. Karmaşık veri kümelerinde daha uygun bir denge sağlamaktadır. Eşitlik (4.4)'te yer alan Dice katsayısı, görüntü segmentasyonu veya nesne tespiti görevlerinde, tahmin edilen segmentasyon maskesi ile gerçek maskenin örtüşmesini ölçmektedir. Eşitlik (4.5)'te yer alan kesinlik metriği ise, tüm pozitif tahminlerin gerçek pozitiflere oranını ölçer, bu nedenle yanlış pozitif değerlerin maliyeti yüksek olduğunda kullanışlı olmaktadır. Bu metrikler, modelin tahminlerini veri kümesindeki gerçek etiketlerle karşılaştırarak çalışır. Gerçekleştirilen göreve bağlı olarak, örneğin, tıbbi teşhislerde yanlış negatifleri en aza indirmek için duyarlılık metriği daha önemlidir.

Doğrusal olmayan aktivasyon fonksiyonu olarak ReLU ve kayıp fonksiyonu olarak ikili çapraz entropi tercih edilmiştir ve Eşitlik (4.6)'da görülmektedir. Eşitlik (4.6)'da yer alan İkili Çapraz Entropi, ikili sınıflandırma görevlerinde kullanılan bir kayıp fonksiyonudur. Düşük değerler elde edilmesi model performansını daha iyi olduğunu göstermektedir.

$$\text{Duyarlılık (DY)} = \frac{TP}{TP+FN} * 100 \quad (4.1)$$

$$\text{Doğruluk (DG)} = \frac{TN+TP}{TN+TP+FN+FP} * 100 \quad (4.2)$$

$$\text{F1 skoru (F1)} = \frac{2*DY*KS}{DY+KS} * 100 \quad (4.3)$$

$$\text{Dice katsayısı (Dice)} = \frac{2*TP}{2*TP+FN+FP} * 100 \quad (4.4)$$

$$\text{Kesinlik (KS)} = \frac{TP}{TP+FP} * 100 \quad (4.5)$$

$$\text{İkili Çapraz Entropi} = -y_1 \log \log (p_1) - (1-y_1) \log(1 - p_1) \quad (4.6)$$

U-Net mimarisinin kodlayıcı bloğunda özellik çıkarımını güçlendirmesi beklenen ResNet50 ve VGG19 modelleri eklenerek U-Net+ResNet50 ve U-Net+VGG19 mimarileri oluşturulmuştur. Önerilen modeller için batch normalizasyonu ve ReLU aktivasyonu içeren evrişimli bir blok tanımlanmıştır. Bu bloklarda eğitim kararlılığının sağlanması aktivasyonları

normalleştirmek için her evrişim katmanından sonra batch normalleştirme uygulanmaktadır. Kodlayıcı bloğunda ResNet50/VGG19 mimarilerine yer verilmiştir. ResNet50 ve VGG19 modelleri önceden eğitilmiş ağırlıkları kullanmaktadır. Kod çözücü blok ise birleştirme ve evrişimli katmanlarını içermekte ve yukarı örnekleme işlemlerini gerçekleştirmektedir.

Tablo 4.2. Önerilen U-Net modellerinin eğitim parametreleri ve değerleri

Parametre	Değer	Değer
Model	U-Net+ResNet50	U-Net+VGG19
Tur (Epok)	50/100/150	100/150
Eğitim Batch	4/8	4/8
Test Batch	1/4	1/4
Öğrenme oranı	0.001	0.001
Aktivasyon fonksiyonu	ReLU	ReLU
Çıkış aktivasyon fonksiyonu	Sigmoid	Sigmoid
Optimizasyon algoritması	Adam	Adam
Kayıp fonksiyonu	İkili Çapraz Entropi	İkili Çapraz Entropi

Çalışmada önerilen kodlayıcı blokta ResNet50 ve VGG19 ile birleştirilmiş U-Net modelleri için tercih edilen eğitim parametreleri Tablo 4.2.'de ve eğitim parametrelerinin terim karşılıkları aşağıda verilmiştir:

Epok: Modelin eğitiminde tüm eğitim veri setinin ileri ve geri yayılım (backpropagation) algoritmasıyla güncellenmesi. Tur sayısı arttıkça model daha iyi eğitilebilir ancak optimum değer aşılması genelleme yeteneğinin azalmasına ve aşırı zaman/kaynak tüketimine yol açabilir.

Eğitim Batch: Modelin eğitim sırasında bir seferde kaç veriyi işleme alacağını göstermektedir. GPU belleğine sığacak kadar küçük olacak şekilde seçilir. Büyük veri gruplarında verisetini hızlı işlemede etkilidir.

Öğrenme oranı: Modelin öğrenme hızı. Her eğitim turunda ağırlıkların ne kadar hızlı veya yavaş güncelleneceğini kontrol eder.

Test Batch: Modelin performansının değerlendirilmesi ayrılan veri kümesinin için belirlenen batch sayısı.

Aktivasyon Fonksiyonu: Modelin karmaşık ilişkileri yakalamasına olanak tanır ve ağdaki katmanların çıktılarını hesaplamak için kullanılır. Görev amacına bağlı olarak ReLU (Rectified Linear Unit), Sigmoid ve tanh kullanılabilir.

Çıkış Aktivasyon Fonksiyonu: Modelin çıktı üretiminde kullanılır. Sınıflandırma problemleri için genellikle softmax, regresyon problemleri için lineer veya sigmoid fonksiyonları kullanılmaktadır.

Optimizasyon Algoritması: Modelin eğitim verileri üzerindeki performansını artırmak için ağırlıkları ayarlar ve günceller.

Kayıp Fonksiyonu: Model tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini hesaplamada kullanılır.

Önerilen U-Net modelinde:

- Çıktı olarak üretilmek istenen segmentasyon maskesi için, son evrişimli katmanda aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edilmiştir. Bu tasarım ile modelin hem kodlayıcı hem de kod çözücü kısımlarında bilgi akışını düzenlenmesi ve daha iyi segmentasyon sonuçlarının elde edilmesi beklenmiştir.
- Derin ağların kullanıldığı bölütleme modellerinde batch boyutu, eğitim kümesinin büyüklüğüne göre daha az bellek kullanımı, kararlı öğrenme ve performans iyileşmesi gibi faktörler göz önünde bulunarak belirlenmektedir. Gerçekleştirilen deneylerde batch boyutu, modelin eğitim aşamasında daha hızlı ve kararlı öğrenmesini sağlamak açısından eğitim kümesi için 8 ve 4; test aşamasında ise test ve doğrulama kümeleri için 4 ve 1 olacak şekilde ayarlanmıştır.
- Modelin eğitimi için epok sayısının değerleri eğitim üzerine etkisini gözlemleyebilmek amacıyla 50, 100 ve 150 olarak kullanılmıştır.
- Adaptif öğrenme yeteneği sayesinde performansa olumlu yönde etki eden Adam optimizasyon algoritması tercih edilmiştir.
- Öğrenme oranı düşük tutularak 0.001 olarak belirlenmiştir.
- Model eğitiminde ReLU aktivasyon fonksiyonu tercih edilmiştir, çünkü ReLU, sinir ağı modellerinde sıkça kullanılan ve hızlı hesaplamalara olanak tanıyan bir doğrusal olmayan aktivasyon fonksiyonudur.

- Çıkış katmanında ise sigmoid aktivasyon fonksiyonu kullanılmıştır; sigmoid fonksiyonu, sonucun $[0,1]$ aralığında olasılık olarak yorumlanmasını sağlamaktadır.
- Ayrıca, modelin performansını değerlendirmek için kayıp fonksiyonu olarak ikili çapraz entropi ve Dice katsayısı, performans metriği olarak doğruluk, kesinlik, duyarlılık ve F1-skor kullanılarak modelin genel başarısı ölçülmüştür. İkili çapraz entropi, modelin tahminlerinin gerçek etiketlere ne kadar yakın olduğunu ölçmektedir. Dice katsayısı ise, özellikle nesne tanıma ve segmentasyonunda kullanılan bir metrik olup, modelin doğruluğunu ve segmentasyon performansını değerlendirmektedir. Bu şekilde, çalışmada amaçlanan segmentasyon görevinde kullanılan yalnızca HD-BET ile kafatası soyma işleminden geçmiş veri setinin segmentasyonu için geliştirilebilir modeller ve aşamalar hazırlanmıştır.
- Çalışma kapsamında hazırlanan modeller Jupyter Notebook geliştirme ortamında Python yazılım dilinde kodlandıktan sonra veri seti üzerinde deneyler gerçekleştirilmeye başlanmıştır.

Veri setindeki MR görüntüleri NifTI (.nii) formatında sıkıştırılmış olduğundan görüntülerin çıkartılması işlemi için tıbbi görüntü segmentasyonu görevlerinde kullanılan yöntemler denenmiştir. Öncelikle, MRG, BT ve PET-BT gibi 3D tıbbi görüntülerin segmentasyonu, görselleştirilmesi ve analizi için kullanılan açık kaynak yazılımı ITK-SNAP (Yushkevich vd., 2006) ile çıkartılması sağlanmıştır. Bu yöntemin ilk dezavantajı kesitlerin belirlenmesindeki el yordamı ile yapılan işlem süresinin uzunluğu ve görüntülerin uygulama işlevlerinden ‘screenshot series’ ile çıkartılmasında farklı boyutlandırmalara sahip oluşudur. Önerilen modellerde gerçekleştirilen deneylerde elde edilen başarımlar düşük olduğu için tez çalışmasına dahil edilmemiştir. Yapılan deney sonuçlarının bir örneği Tablo 4.3.’te gösterilmektedir.

Tablo 4.3. ITK-SNAP ile el yordamı çıkartılan DAG kesitlerinin U-Net modeli için performans metriklerinin ortalamalarına göre sonuçları


Vaka sayısı	Batch (eğitim)	Batch (test)	Epok sayısı	İterasyon sayısı	Test süresi (sn)	Toplam eğitim süresi (dk)	Dice	Loss
100	4	1	50	463	0.033	104.16	0.021	0.99

Görüntülerin çıkarılmasında ikinci yöntem olarak nibabel kütüphanesi (Brett vd., 2021) kullanılmıştır. Difüzyon MR görüntülerin aksiyel düzlemi kullanılarak orjinal boyutlarında (112x112 piksel) PNG formatında çıkarılmıştır. Toplam 15731 görüntü elde edildikten sonra uzman maskesi içermeyenler ayıklanmış ve 4827 görüntü elde edilmiştir. Görüntüler orjinal boyutlarında ve 256x256 piksel boyutunda yeniden boyutlandırma yapılarak testlere tabi tutulmuştur. Testlerdeki parametre değerlerini ve performansını gösteren ölçüm sonuçları Tablo 4.4.'te verilmiştir.

Tablo 4.4. ResNet50 mimarisinin kullanıldığı U-Net modeli (U-Net+ ResNet50) için DAG taramalarının performans metriklerinin ortalamalarına göre sonuçları


Görüntü boyutu	Vaka sayısı	Batch (eğitim)	Batch (test)	Epok sayısı	İterasyon sayısı	Test süresi (sn)	Toplam eğitim süresi (dk)	F1	Dice	KS	DY	Loss	DG
256x256	250	4	1	50	1053	0.017	148.13	0.55	0.52	0.65	0.47	0.54	0.994
256x256	100	4	1	100	1053	0.019	300.47	0.60	0.58	0.70	0.53	0.37	0.994
256x256	250	4	1	100	1053	0.016	294.78	0.61	0.60	0.66	0.57	0.36	0.995
256x256	250	4	1	150	1053	0.017	437.16	0.65	0.60	0.66	0.64	0.44	0.989

Sonraki aşamada değerlendirmeler sonucunda MR tarama başlangıcı ve sonuna denk geldiği için başarımı düşürdüğü belirlenen yeterli veya hiç maskeye sahip olmayan görüntüler ayıklandıktan sonra 4193 görüntü ile performans testleri gerçekleştirilmiştir. Ayıklanan MR görüntülerine ait örnekler Şekil 4.2.'de verilmiştir.



Şekil 4.2. Aynı hastaya ait sırasıyla MR başlangıç(üst) ve bitişine(alt) denk gelen görüntüler

Kodlayıcı blokta ResNet50 kullanılan U-Net+ResNet50 modelinin ADC ve DAG taramalarındaki performans metriklerine göre bölütleme başarısının ölçümleri Tablo 4.4. ve Tablo 4.5.'te verilmiştir. ADC taramasından elde edilen görüntülere uygulanan testte yer alan inme lezyonlarının görüldüğü kesitler ve segmentasyon maskeleri Şekil 4.3.'te yer almaktadır.




Şekil 4.3. U-Net+ResNet50'e göre bazı ADC MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları

Tablo 4.4., Tablo 4.5. ve Tablo 4.6.'da önerilen U-Net+ResNet50 modellerinden kodlayıcı olarak ResNet50 mimarisinin kullanıldığı model için F1-skoru, Dice, Kesinlik ve Duyarlılık metrikleri ile elde edilen sonuçlar görülmektedir. Her iki tabloda da gösterilen sonuçlara göre, batch boyutunun 8 ve epok sayısının 150 olduğu performans testinde en iyi skorlar gözlemlenmiştir. Model performansının en iyi olduğu testte Loss değerinin 0.18 ile en

düşük, Dice skoru için 0.79 ve F1 skoru 0.85 ile en yüksek oranlara sahip olmuştur. Önerilen yöntemde en iyi sonuçların çıktığı olarak alındığı testte yer alan inme lezyonlarının kesitleri ve segmentasyon maskelerine ait örnekler Şekil 4.4.'te yer almaktadır.

Tablo 4.5. U-Net+ResNet50 mimarisinin kullanıldığı U-Net modeli için ADC görüntülerinin performans metriklerinin ortalamalarına göre sonuçları

Görüntü boyutu	Batch (eğitim)	Batch (test)	Epok sayısı	İterasyon sayısı	Test süresi (sn)	Toplam eğitim süresi (dk)	F1	Dice	KS	DY	Loss	DG
256x256	8	4	100	915	0.022	461.32	0.49	0.49	0.56	0.48	0.40	0.989



Şekil 4.4. U-Net+ResNet50'e göre bazı difüzyon MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları

Tablo 4.6. Veri setinde yapılan el yordamı ile yapılan ayıklama sonrası ResNet50 mimarisinin kullanıldığı U-Net+ResNet50 modeli için DAG taramalarının performans metrikleri ortalamalarına göre sonuçları

Görüntü boyutu	Batch (eğitim)	Batch (test)	Epok sayısı	İterasyon sayısı	Test süresi (sn)	Toplam eğitim süresi (dk)	F1	Dice	KS	DY	Loss	DG
256x256	8	8	100	915	0.038	471.57	0.71	0.71	0.77	0.78	0.20	0.989
256x256	8	4	150	915	0.016	687.13	0.85	0.79	0.86	0.87	0.18	0.996
256x256	8	4	100	915	0.026	455.66	0.76	0.71	0.80	0.74	0.27	0.991
112x112	8	4	100	915	0.018	98.37	0.59	0.56	0.58	0.60	0.36	0.992
256x256	4	1	150	915	0.028	375.25	0.76	0.72	0.80	0.77	0.35	0.990
256x256	4	1	100	915	0.031	294.78	0.74	0.67	0.76	0.73	0.36	0.989
256x256	4	1	50	915	0.024	148.13	0.55	0.51	0.65	0.47	0.54	0.988


Diğer taraftan, VGG19 mimarisinin kodlayıcı blokta kullanıldığı U-Net modeli (U-Net+ VGG19) için segmentasyon performans sonuçları Tablo 4.7.'de verilmiştir. Şekil 4.5.'te ise modelin uygulanması sonucunda elde edilen bazı lezyonlardaki bölütleme sonuçları sunulmuştur.

Tablo 4.7. Kodlayıcı olarak VGG19 mimarisinin kullanıldığı U-Net+ VGG19 modeli için performans metrikleri ortalamalarına göre sonuçları

Görüntü boyutu	Batch boyutu	Epok sayısı	İterasyon sayısı	Test süresi (sn)	Toplam eğitim süresi (dk)	F1	Dice	KS	DY	Loss	DG
256x256	8	150	915	0.019	683.78	0.83	0.77	0.83	0.85	0.21	0.991
256x256	8	100	915	0.017	452.94	0.80	0.76	0.79	0.84	0.25	0.991

Tablo 4.7.'de görüldüğü gibi, önerilen U-Net modeli için en iyi performans batch boyutunun 8 ve epok sayısının 150 olduğu testte elde edilmiştir. Belirtilen testte Dice skoru 0.77 ve F1-skoru için 0.83 oranlarına sahiptir. ResNet50 ile birleştirilmiş U-Net modeli ile

kıyaslandığında, inme lezyonlarının bölütlenmesindeki başarının daha düşük olduğu gözlemlenmektedir.



Şekil 4.5. U-Net+ VGG19'e göre bazı difüzyon MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları

4.1. Önerilen Yöntemlerin Karşılaştırması

Tez çalışması kapsamında, U-Net+ResNet50 ve U-Net+VGG19 modellerinin medikal taramalar üzerindeki segmentasyon performansı değerlendirilmiştir. Çalışmada, ISLES'22 yarışmasında yayınlanan iskemik inme vakalarına ait DAG ve ADC MR tarama görüntüleri kullanılmış olup ve tez çalışması ile hedeflenen bir diğer görev olarak veri hazırlama aşamasını kolaylaştıracak bir ortam geliştirilmesine odaklanılmıştır. Veri hazırlama aşamasında Python yazılım dilinde hazırlanan kod blokları ile sıkıştırılmış NifTI formatındaki görüntülerin istenilen boyutta ve uzman etiketlerinin bulunduğu MR kesitleri kalacak şekilde ayarlanması gerçekleştirilmiştir.

Bu tez çalışmasında farklı mimarilerle birleştirilmiş U-Net+ResNet50 ve U-Net+VGG19 olmak üzere iki U-Net modeli önerilmiştir. Modellerin eğitiminde kullanılacak parametreler ve değerleri verimliliği ve öğrenmeyi iyileştirmek için düzenlenmiştir.

İlk modelde kullanılan olan ResNet50, transfer öğrenme yeteneğine sahiptir. Bu yeteneği ile önceden eğitilmiş ağırlıkları kullanarak segmentasyon görevinde anlam ilişkileri yüksek özellik haritaları çıkarması beklenmiştir. Bu sebeple çalışmada ilk aşama olarak ResNet50 mimarisinin kodlayıcı blokta çıkardığı özellikler U-Net'in kod çözücü bloğuna aktararak segmentasyon işlemi gerçekleştirilmiştir. İkinci modelde ise, VGG19 ile U-Net

modeli birleştirilmiş ve yüksek başarımla elde edilen testler tekrarlanmıştır. Her iki modelin veri dağılımları Tablo 4.8.'de ve elde edilen başarımların değerleri Tablo 4.9.'da verilmiştir.

Tablo 4.8. Önerilen U-Net modeli için kodlayıcı olarak kullanılan CNN mimarileri ve veri dağılımları


Algoritma	Katman sayısı	Girdi Boyutu	Eğitim Kümesi	Test Kümesi	Toplam veri sayısı	Doğruluk Oranı	Eğitilebilir parametre sayısı	Toplam parametre sayısı
U-Net+VGG-19	63	256x256x3	%87	%0.03	4193	0.996	31025057	31029025
U-Net+ResNet50	176	256x256x3	%87	%0.03	4193	0.991	20642545	20676545

Tablo 4.9. Önerilen U-Net modelleri ile en yüksek başarımla sahip testlerin performans metriklerinin ortalamalarına göre sonuçları

Algoritma	Görüntü boyutu	Batch boyutu	Epok sayısı	İterasyon sayısı	Test süresi (sn)	Toplam eğitim süresi (dk)	F1	Dice	KS	DY	Loss	DG
U-Net+VGG-19	256x256	8	150	915	0.019	683.78	0.83	0.77	0.83	0.85	0.21	0.991
U-Net+ResNet50	256x256	8	150	915	0.016	687.13	0.85	0.79	0.86	0.87	0.18	0.996

Tez çalışması süresince yapılan testler, önerilen her iki derin öğrenme modelinin de iskemik inme verileri üzerindeki performanslarının geliştirilebilir olduğunu göstermiştir. Medikal görüntülerde segmentasyon görevine odaklanan çalışmalarda, modelin öğrenme oranını artırmak için daha geniş ve heterojen veri kümelerinin kullanımının gerekliliği, aksi takdirde kullanılacak derin öğrenme algoritmalarının uyumlu olacak şekilde seçilmesi gerektiği testler sonucunda anlaşılmaktadır. Modeller büyük lezyonların tespitinde oldukça başarılı olmalarına rağmen, küçük lezyonlarda performansın düştüğü gözlemlenmiş olup, Şekil 4.6.'da bu lezyonlara ait örnekler verilmiştir. Küçük boyuta sahip lezyonlar bütün veri setinin %66'sını oluşturmaktadır. Bu durum test kümesi üzerinde elde edilen ortalama değerlerin düşük bulunmasına sebep olmaktadır. Ayrıca klinik kullanımda ihtiyaç duyulan ham verilerden bölütleme yapabilmeye yeteneğinin veri ön işleme sürecinde uygulanabilir olduğu görülmüştür.

Elde edilen sonuçlar, literatürdeki araştırmalarla tutarlılık göstermekte ve derin öğrenme modellerinin medikal görüntü segmentasyonu alanında önemli bir potansiyele sahip olduğunu doğrulamaktadır. Önceki çalışmalarda da vurgulandığı gibi, daha geniş ve çeşitli veri kümelerinin kullanımı, derin öğrenme modellerinin öğrenme yeteneğini artırarak genelleme performansını iyileştirebilir.



Şekil 4.6. Performans testlerinde başarıyı düşüren küçük boyutlu lezyonlar

Özellikle, küçük lezyonların tespitindeki düşük başarı oranı, modelin daha hassas hale getirilmesi ve çeşitli veri setleriyle eğitilmesi gerekliliğini öne çıkarmaktadır. Bu nedenle, gelecekteki araştırmaların, model performansını artırmak için daha büyük ve çeşitli veri kümelerine odaklanmaları ve kullanılan modellerin lezyon boyutlarına göre öğrenme ağırlıklarının ayarlanması başarıda etkili artışlar sağlayacaktır. Ayrıca, klinik kullanımda önemli olan ham verilerden bölütlenme yapabilme becerisinin, veri ön işleme aşamasında uygulanabilir olduğu bulgusu, bu tekniklerin pratikteki uygulanabilirliğini güçlendirmektedir. Bu çıkarımlardan hareketle, ön işlem sürecinin kolaylaştırılması ve model performansının iyileştirilmesinin yanında, gelecek çalışmalarda literatürde daha önce de değinilen yorumlayabilme yeteneği üzerinde durulması da klinik uygulamalarda aktif kullanılacak sistemlerin geliştirilmesine yardımcı olacaktır. Özetle, derin öğrenme modellerinin medikal görüntü segmentasyonunda başarıyla uygulanabilmesi için daha fazla araştırma ve geliştirme

gerekmektedir, ancak bu tez çalışmasında elde edilen sonuçlar gelecekteki çalışmalar için önemli bir temel oluşturabilir.

5. TARTIŞMA

Tez çalışmasında konu edinilen iskemik inme vakalarının MR görüntüleri üzerinde bölütleme işlemi, inme hastalığının acil müdahale gerektiren, bireyin sağlık durumunda geri dönülemez veya tedavisi zor hasarlara sebep olması nedeniyle güvenilir sonuçlar alınarak klinik sürecin hızlandırılması gerekliliğine öncelik vermektedir. İnme vakalarında ayrıntılı bilgi edinilmesini sağlayan MR görüntülerinin uzmanlarca incelenme ve teşhise elverişli raporlama süreci, aciliyetin söz konusu olduğu bu gibi durumlar için zaman alıcı ve hatta daha etkili çözümler alınabilen tıbbi tedavilerin uygulanmasını geciktirici olabilmektedir. Klinik uygulamalarda kullanıma uygun seviyede yüksek tutarlılık ve doğruluğa sahip otomatik yöntemler, hastalığın hızlı ve doğru bir şekilde teşhis edilmesini sağlayabilir. Bu yöntemler, MR görüntülerinin analizinde oluşabilecek insan hatasını en aza indirerek, hastaların zamanında ve fiziksel veya yaşamsal işlev kayıplarını önleyebilecek etkili tedavilerin uygulanmasına olanak tanır. Ayrıca, otomatik bölütleme yöntemleri, inme vakalarının tespit edilmesi için gereken süreyi kısaltarak, klinik kaynakların daha etkin bir şekilde kullanılmasına yardımcı olabilir. Bu nedenle, iskemik inme vakalarında MR görüntülerinin otomatik olarak bölütleme işlemine odaklanan tez çalışmamız ile klinik uygulamalarda önemli bir katkı sağlayabilmesi ve bireylerin sağlık durumlarını olumlu yönde etkileyebilmesi hedeflenmiştir.

ISLES'22 Akut ve Subakut İnmede Multimodal MRG Enfarktüs Segmentasyonu verisetinin kullanıldığı literatürde yer alan benzer çalışmalar için Dice performans metriğinin karşılaştırması Tablo 5.1.'de verilmiştir.

Tablo 5.1. Literatürde ISLES'22 veriseti ile yapılan çalışmalar ve tez çalışmasının karşılaştırılması

Çalışma	Yıl	MR sekansı	Yöntem	Dice
(Li, vd., 2023)	2023	DAG	Markovian olmayan difüzyon	0.54
(Chen, vd., 2023)	2023	DAG, ADC	MSA-YOLOv5	0.89 (0.80 IoU)
(Johansen, vd., 2024)	2024	DAG, FLAIR	U-Net, eşikleme	0.82
Tez çalışması	2024	DAG, ADC	U-Net+VGG19	0.77
			U-Net+ResNet50	0.79

Diğer çalışmalarda ulaşılan en iyi Dice değeri 0.89 ile Chan ve ark. (Chen vd., 2023) tarafından önerilen MSA-YOLOv5 yönteminde elde edildiği görülmektedir. Ardından

Johansen ve ark. (Johansen vd., 2024) tarafından önerilen U-Net modeli ile DAG/FLAIR uyumsuzluk değerlendirme yapılan çalışmada Dice değeri 0.82 olarak görülmektedir. Bir diğer çalışmada önerilen hızlı non-Markov difüzyon modeli (FNMD) ise 0.54 ile düşük Dice metriği başarımına sahiptir. Dice metriğine bakıldığında 0.77 ve 0.79 değerleri ile tez çalışmasının segmentasyon performansının diğer çalışmalara yakın ancak kıyasla daha düşük olduğu söylenebilir.

Bu tez çalışmasında iskemik inme vakalarının klinik başvurularında hekimlerin tedaviye karar verme ve uygulamaya geçiş sürecinde sahip oldukları kısıtlı zaman göz önünde tutularak bilgisayar destekli yöntemler ile bu zorluğun aşılmasına yardımcı çözümler geliştirmeye odaklanılmıştır. Bunun için derin öğrenme mimarilerinden U-Net kullanılarak yüksek doğrulukta bölütleme yapabileceği öngörülerek bir sistem geliştirilmiş ve ISLES'22 global veriseti üzerindeki başarımı ölçülmüştür. ResNet50 ile birleştirilmiş U-Net modelinde VGG19'a kıyasla F1 metriği 0.83 yerine 0.85, Dice metriği 0.77 yerine 0.79 ve doğruluk metriği ise 0.991 yerine 0.996 olarak ölçülmüştür. Her iki U-Net modeli ile gerçekleştirilen testlerde doğruluk metriği yüksek değerlerde görülmektedir. Verisetinde küçük lezyonlara sahip olan görüntülerin sayıca fazlalığı ve bölütleme görevinde kullanılan sigmoid aktivasyon fonksiyonunun görüntüleri ikili sınıflara ataması bu durumun nedenleri olarak gösterilebilir. Lezyon bölgelerinin, MR tarama görüntülerinde az yer kaplaması dolayısıyla lezyon içeren ve içermeyen piksellerin doğru sınıflara atanmasındaki doğruluk oranı optimum değere yaklaşmakla birlikte kullanılan veriseti için ayırıcı bilgi edinilemeyecek bir performans değerlendirme metriği olarak görülmüştür.

Bu tez çalışması ile, ISLES'22 gibi daha küçük boyut ve düzensiz şekillere sahip inme lezyonlarının olduğu zorlu verisetlerinde dahi, iskemik inme vakalarının teşhis sürecinde bilgisayar destekli yöntemlerin önemli bir rol oynayabileceği ve geliştirilen modellerin yüksek doğruluklara ulaşabileceği görülmektedir. Çalışmada tercih edilen modellerin öğrenme yeteneğini artıracak geliştirmeler ile başarımın artacağı düşünülmektedir. Bu iyileştirmeler, modelin daha verimli bir şekilde genelleme yeteneğini artırarak, farklı veri kümelerinde de daha iyi performans göstermesine yardımcı olabilir. Bu nedenle, gelecekte yapılacak çalışmalarda bu tür geliştirmelerin dikkate alınması önemlidir. Sonuç olarak, bu çalışma iskemik inme teşhisinde bilgisayar destekli yöntemlerin potansiyelini ortaya koymuş ve gelecekteki araştırmalara yol göstermiştir. Bu alandaki ilerlemeler, iskemik inme vakalarının erken teşhisini sağlayarak, tedavi süreçlerinin hızlandırılmasına ve iyileştirilmesine katkı sağlayabilecektir.

6. SONUÇLAR VE ÖNERİLER

Son yıllarda derin öğrenme modellerinin başarılı sınıflandırma ve segmentasyon görevlerini gerçekleştirildiği görülmektedir. Özellikle medikal görüntüleme yöntemleri ile kullanımında gün geçtikçe daha iyi performansa sahip yöntemler geliştirilmektedir. Bu tez çalışmasında, ISLES'22 kapsamında yayınlanan 250 vakaya ait 15.676 DAG MR görüntüleri üzerinde iskemik inme segmentasyonunu ResNet50 ve VGG19 tabanlı U-Net modelleri ile hassas bir şekilde gerçekleştirebilen ve segmentasyon sürecinde veri hazırlama aşamasını kolaylaştıran bir ortam geliştirilmiştir. Çalışmada kullanılan modeller ve mimariler hastalığın teşhisi ve tedaviye karar verme sürecindeki bilgisayar destekli yöntemlere duyulan ihtiyaca katkı sağlamak amacıyla geliştirilmiş ve performansları ölçülmüştür.

Çalışmada U-Net mimarisi ile birleştirilmiş ResNet50 modeliyle ağın eğitimi gerçekleştirilmiş ve segmentasyon haritaları elde edilmiştir. Modelde ResNet50 modelinin tercih edilme sebebi transfer öğrenme yeteneğinin modelin öğrenmesini iyileştirecek anlamlı ve kapsayıcı özellik haritaları çıkarabilme yeteneğidir. VGG19'un genel özellikleri yakalayabilmesi ve karmaşıklıktan uzak ağ yapısından faydalanarak VGG19 ile birleştirilmiş U-Net modelinin bölütleme başarısının artması hedeflenmiştir.

DAG sekansına ait görüntülerin yüksek çözünürlüğe sahip oluşu eğitim aşamasında modelin iskemik lezyonları doğru bir şekilde öğrenmesinde etkili olmuştur. Performans testleri öncelikle U-Net+ResNet50 modeli ile gerçekleştirilmiş ve optimum parametreler baz alınarak U-Net+VGG19 modeli ile yenilenmiştir. Yapılan testlerde en iyi performans ResNet50 mimarisi ile birleştirilen U-Net modelinde düzenlenen hiperparametre ayarlamaları ile elde edilmiştir. Öğrenmeyi iyileştirecek batch ve epok sayıları belirlenerek modellerin başarımı gözlenmiştir. En iyi başarıma sahip olan testler 150 epok ve 8 batch sayısına sahip veri içermeyen görüntüler ayıklandıktan sonra kalan 4193 görüntü ile elde edilmiştir. Bu testlerde, U-Net+ResNet50 modeli performans metriklerinde 0.85 F1, 0.79 Dice, 0.996 doğruluk, 0.86 kesinlik, 0.87 duyarlılık değerlerine 0.18 kayıp ile ulaşmıştır. U-Net+VGG19 modeli ise 0.83 F1, 0.77 Dice, 0.991 doğruluk, 0.83 kesinlik ve 0.85 duyarlılık değerlerine 0.21 kayıp ile ulaşmıştır. Bölütleme süresi U-Net+VGG-19 modelinde yaklaşık 0.019 sn ve U-Net+Resnet-50 modelinde yaklaşık 0.016 sn olmuştur. Her iki modelde de genel anlamıyla lezyon büyüklüğü konusunda zorluklar görülmüştür. Küçük lezyonlarda başarımlar düşerken büyük lezyonlarda çok daha doğru bölütlemelerin yapıldığı görülmüştür. Küçük boyuttaki lezyonların verisetindeki yoğunluğunun fazla olması sebebiyle modelin uygun öğrenme ağırlıklarında daha iyi performans göstereceği öngörülmüştür.

Sonuç olarak, derin öğrenme yöntemlerinin iskemik inme lezyonlarının bölütlemesinde başarısının gelişmeye açık olduğu ve U-Net mimarisinin farklı mimarilerle uygun kombinasyonlarının verimi daha da artıracığı düşünülmektedir. Tıbbi görüntü bölütleme yöntemlerinde doğruluğun ve işlem sürelerinin önemi göz önüne alındığında geliştirilecek derin öğrenme yöntemlerinin daha geniş ve kapsamlı verisetlerinde öğrenme gerçekleştirmesinin performans başarımında etkili olacağı sonucuna varılmıştır.

KAYNAKÇA

Albach, F. N. vd. (2013). Complete early reversal of diffusion-weighted imaging hyperintensities after ischemic stroke is mainly limited to small embolic lesions. *Stroke*, 44(4), 1043–1048. <https://doi.org/10.1161/STROKEAHA.111.676346>.

Al Attar, F.N. vd. (2022). Automatic detection of ischemic-stroke-lesion with CNN segmentation: a study. *Journal of Physics: Conference Series*, 2318. DOI:10.1088/1742-6596/2318/1/012049.

Ali, N. H. vd. (2021). Brain stroke computed tomography images analysis using image processing: A review. *IAES International Journal of Artificial Intelligence (IJ-AI)*, 10(4), 1048–1059. <https://doi.org/10.11591/ijai.v10.i4.pp1048-1059>.

Altıntaş, M. (2021). Bilgisayarlı Tomografi Görüntülerinde İnmenin Farklı Derin Öğrenme Modelleri ile Sınıflandırılması (Yüksek Lisans Tezi). [Classification of Stroke in Computed Tomography Images Using Different Deep Learning Models (Master's Thesis)].

Andersen, K. K., Olsen, T. S., Dehlendorff, C., & Kammersgaard, L. P. (2009). Hemorrhagic and ischemic strokes compared: stroke severity, mortality, and risk factors. *Stroke*, 40(6), 2068-2072. DOI: 10.1161/STROKEAHA.108.540112. PMID: 19359645.

Arf, C. (1959). Makine Düşünebilir Mi ve Nasıl Düşünebilir? [Can Machines Think and How Can They Think?]. *Atatürk Üniversitesi- Üniversite Çalışmalarını Muhite Yayma ve Halk Eğitimi Yayınları Konferanslar Serisi* No: 1, Erzurum, s. 91-103.

Asil, T. vd. (2011). Cost of acute ischemic and hemorrhagic stroke in Turkey. *Clinical Neurology and Neurosurgery*, 113(2), 111-114. <https://doi.org/10.1016/j.clineuro.2010.09.020>.

Brett, M. vd. (2021). *NiBabel*. <https://nipy.org/nibabel>.

Buchanan, Bruce G. A (2005). (Very) Brief History of Artificial Intelligence. *AI Magazine* 26(4): Winter 2005, 53–60.

Campbell, B.C.V. vd. (2019). Ischaemic stroke. *Nature Reviews Disease Primers* 5, 70. DOI: 10.1038/s41572-019-0118-8.

Chen, L., Bentley, P., & Rueckert, D. (2017). Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks. *NeuroImage: Clinical*, Volume

15, Pages 633-643, ISSN 2213-1582. <https://www.elsevier.com/locate/ynicl> (<https://doi.org/10.1016/j.nicl.2017.06.016>).

Chen, S. vd. (2023). MSA-YOLOv5: Multi-scale attention-based YOLOv5 for automatic detection of acute ischemic stroke from multi-modality MRI images. *Computers in Biology and Medicine*, 165, 107471. <https://doi.org/10.1016/j.compbiomed.2023.107471>.

Cioffi, R.; Travaglioni, M.; Piscitelli, G.; Petrillo, A.; De Felice, F. (2020). Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions. *Sustainability*. 2020; 12(2):492. <https://doi.org/10.3390/su12020492>.

Cockburn, I. M., Henderson, R., & Stern, S. (2019). The Impact of Artificial Intelligence on Innovation: An Exploratory Analysis. In A. Agrawal, J. Gans, & A. Goldfarb (Eds.), *The Economics of Artificial Intelligence: An Agenda* (pp. 115-146). University of Chicago Press. Retrieved from <http://www.nber.org/chapters/c14006>.

Cui, L. vd. (2022). Deep Learning in Ischemic Stroke Imaging Analysis: A Comprehensive Review. *BioMed Research International*, vol. 2022, Article ID 2456550, 15 pages. DOI: 10.1155/2022/2456550.

Deuschl, G., vd. (2020). The burden of neurological diseases in Europe: An analysis for the Global Burden of Disease Study 2017. *The Lancet Public Health*, 5(10), E551-E567. [https://doi.org/10.1016/S2468-2667\(20\)30190-0](https://doi.org/10.1016/S2468-2667(20)30190-0).

Du, G., Cao, X., Liang, J., Chen, X., & Zhan, Y. (2020). Medical Image Segmentation based on U-Net: A Review. *Journal of Imaging Science and Technology*, 64(2), 20508–1–20508–12. DOI:10.2352/j.imagingsci.technol.2020.64.2.020508.

Dubey, P., Pandey, S. & Moonis, G. (2013). Acute Stroke Imaging: Recent Updates. *Stroke Research and Treatment*, vol. 2013, Article ID 767212, 6 pages, 2013. <https://doi.org/10.1155/2013/767212>.

Ehab, W., & Li, Y. (2023). Performance Analysis of UNet and Variants for Medical Image Segmentation. London.

Elen, A. (2020). Görüntü İkileştirme için Global Eşikleme Yöntemleri Üzerine Bir İnceleme. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 2(2), 38-49. <https://doi.org/10.46387/bjesr.789534>.

Fawzi, A., Achuthan, A., & Belaton, B. (2021). Brain Image Segmentation in Recent Years: A Narrative Review. *Brain sciences*, 11(8), 1055. <https://doi.org/10.3390/brainsci11081055>.

Feigin, V. L. & Global Burden Contributors. (2021). Global, regional, and national burden of stroke and its risk factors, 1990–2019: a systematic analysis for the Global Burden of Disease Study 2019. *The Lancet Neurology*, 20(10), 795-820. DOI: 10.1016/S1474-4422(21)00252-0.

Flowers, J. C. (2019). Strong and weak AI: Deweyan considerations. *AAAI Spring Symposium: Towards Conscious AI Systems*.

Franke, M., & Degen, J. (2023). The softmax function: Properties, motivation, and interpretation. <https://doi.org/10.31234/osf.io/vsw47>.

Grace, K., Salvatier, J., Dafoe, A., Zhang, B., and Evans, O. (2018). When will AI exceed human performance? Evidence from AI experts. *J. Artif. Intell. Res.* 62, 729–754. DOI: 10.1613/jair.1.11222.

Grau, A. J. vd. (2001). Risk Factors, Outcome, and Treatment in Subtypes of Ischemic Stroke: The German Stroke Data Bank. *Stroke*, 32(11), 2559–2566. DOI: 10.1161/hs1101.098524.

Gezer, M., (2021). Tıpta Görüntü İşleme Yöntemleri. *Tıp Bilişimi* (pp.203-218), İstanbul: İstanbul University.

Hand, P. J. vd. (2006). MR diffusion-weighted imaging and outcome prediction after ischemic stroke. *Neurology Journals*, 66 (8) 1159-1163. <https://doi.org/10.1212/01.wnl.0000202524.43850.81>.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).

Hernandez Petzsche, M. R. vd. (2022). ISLES 2022: A multi-center magnetic resonance imaging stroke lesion segmentation dataset. *Scientific Data*, 9(1), 762.

Hobohm, C. vd. (2014). Predicting intracerebral hemorrhage by baseline magnetic resonance imaging in stroke patients undergoing systemic thrombolysis. *Acta Neurologica Scandinavica*, 130. <https://doi.org/10.1111/ane.1227>.

Hoggard, N., Wilkinson, I. D., & Griffiths, P. D. (2001). The Imaging of Ischaemic Stroke. *Clinical Radiology*, 56(3), 171–183. <https://doi.org/10.1053/crad.2000.0619>.

Isensee, F. vd. (2019). Automated brain extraction of multisequence MRI using artificial neural networks. *Human Brain Mapping*, 40(17), 4952-4964. <https://doi.org/10.1002/hbm.24750>.

Johansen, J. vd. (2024). An Automatic DWI/FLAIR Mismatch Assessment of Stroke Patients. *Diagnostics*, 14, 69. <https://doi.org/10.3390/diagnostics14010069>.

Kadry, S., Damaševičius, R., Taniar, D., Rajinikanth, V., & Lawal, I. A. (2021). U-Net Supported Segmentation of Ischemic-Stroke Lesion from Brain MRI Slices. In *Seventh International Conference on Bio Signals, Images, and Instrumentation (ICBSII)* (pp. 1-6). IEEE. DOI: 10.1109/ICBSII51839.2021.9445126.

Kamal, H., Lopez, V., & Sheth, S. A. (2018). Machine Learning in Acute Ischemic Stroke Neuroimaging. *Frontiers in Neurology*, 9, 945. DOI: 10.3389/fneur.2018.00945. PMID: 30467491; PMCID: PMC6236025.

Karthik, R., Menaka, R., Johnson, A. & Anand, S. (2020). Neuroimaging and deep learning for brain stroke detection—A review of recent advancements and future prospects. *Comput. Methods Programs Biomed.* 2020, 197, 105728.

Katan, M. & Luft, A. (2018). Global Burden of Stroke. *Seminars in Neurology*, 38(2), 208-211. DOI: 10.1055/s-0038-1649503. Thieme Medical Publishers.

Kim, J. vd. (2020). Global Stroke Statistics 2019. *International Journal of Stroke*. 2020;15(8):819-838. DOI: 10.1177/1747493020909545.

Kloska, S.P. vd. (2010) Acute stroke magnetic resonance imaging: current status and future perspective. *Neuroradiology* 52, 189–201. DOI: 10.1007/s00234-009-0637-1.

Köseoğlu Toksoy, C. vd. (2018). Stroke Prevalence in a Coastal Town on the Black Sea Coast in Turkey: Community Based Study. *Neurology Research International*. 2018, (5) pages. <https://doi.org/10.1155/2018/8246123>.

LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>.

Li, J., Cao, H., Wang, J., Liu, F., Dou, Q., Chen, G., & Heng, P.-A. (2023). Fast Non-Markovian Diffusion Model for Weakly Supervised Anomaly Detection in Brain MR

Images. *In Medical Image Computing and Computer Assisted Intervention – MICCAI 2023* (pp. 579–589). Lecture Notes in Computer Science (LNCS), 14224. https://doi.org/10.1007/978-3-031-43904-9_56.

Li, X., Li, M., Yan, P., Li, G., Jiang, Y., Luo, H., & Yin, S. (2023). Deep Learning Attention Mechanism in Medical Image Analysis: Basics and Beyonds. *International Journal of Network Dynamics and Intelligence*. 2(1), 93–116. DOI: 10.53941/ijndi0201006.

Mali, W. P. (1998). Diffusion-weighted magnetic resonance imaging in acute stroke. *Stroke*, 29(9), 1783-1790. <https://doi.org/10.1161/01.str.29.9.1783>.

Malik, M. vd. (2024). Stroke Lesion Segmentation and Deep Learning: A Comprehensive Review. *Bioengineering*. 11(1):86. DOI: 10.3390/bioengineering11010086.

Mascarenhas, S.&Agarwal, M. (2021). A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification. *2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications (CENTCON)*, Bengaluru, India, 2021, pp. 96-99, DOI: 10.1109/CENTCON52345.2021.9687944.

McCarthy, J. (1968). Semantic Information Processing. In M. Minsky (Ed.), *Semantic Information Processing* (pp. 403-418). Cambridge, MA: The MIT Press.

McCarthy, J. (1983). *The Little Thoughts of Thinking Machines*. Computer Science Department, Stanford University, Stanford, CA 94305. Retrieved from <http://www-formal.stanford.edu/jmc/>.

Minematsu, K. (2003). MR imaging in acute stroke. *International Congress Series*, 1252, 309–314. [https://doi.org/10.1016/S0531-5131\(03\)00081-5](https://doi.org/10.1016/S0531-5131(03)00081-5).

Omarov, B. vd. (2022). Modified UNet Model for Brain Stroke Lesion Segmentation on Computed Tomography Images. *Computers, Materials & Continua*. Advance online publication. DOI:10.32604/cmc.2022.020998.

Özsunar, Y., Huisman, T. & Sorensen, A. G. (2003). Clinical indications of Diffusion Weighted MR Imaging. *Turk J Neurol*. 2003; 9(1): 153-162.

Öztürk, N. & Öztürk, S. (2018). Görüntü Bölütleme Yöntemlerinin Karşılaştırılması [Comparing Image Segmentation Methods]. *In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP)* (pp. 1-4). Malatya, Turkey. DOI:10.1109/IDAP.2018.8620739.

Polat, Ö., & Kartal, M. S. (2023). Derin öğrenme ile pencere ayarlı görüntüler kullanılarak beyin inme segmentasyon performansının geliştirilmesi. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 13(4), 1094-1109. <https://doi.org/10.17714/gumusfenbil.1319024>.

Azad, R. vd. (2022). Medical Image Segmentation Review: The success of U-Net. . arXiv preprint. arXiv.2211.14830.

Roeder, L. (2023). NETRON. *GitHub*. <https://github.com/lutzroeder/netron>.

Rogowska, J. (2000). Overview and fundamentals of medical image segmentation. *Handbook of medical imaging, processing and analysis*, 69-85.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*.

Sharma, O. (2019). A New Activation Function for Deep Neural Network. *International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, Faridabad, India, 2019, pp. 84-86, DOI: 10.1109/COMITCon.2019.8862253.

Sharma, A. K. vd. (2023). Brain tumor classification using the modified ResNet50 model based on transfer learning. *Biomedical Signal Processing and Control*, 86(Part C), 105299. <https://doi.org/10.1016/j.bspc.2023.105299>.

Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V. (2021). U-Net and Its Variants for Medical Image Segmentation: A Review of Theory and Applications. *IEEE Access*. DOI: 10.1109/ACCESS.2021.3086020.

Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint. arXiv:1409.1556.

Şenel, G. B. vd. (2019). A survey from Turkey and Iran on comparison of risk factors and etiology in ischemic stroke. *Iranian Journal of Neurology*, 18(4), 176-178. PMID: 32117554; PMCID: PMC7036052.

Truelsen, T., & Bonita, R. (2008). Chapter 16 The worldwide burden of stroke: current status and future projections. *In Handbook of Clinical Neurology (Vol. 92, pp. 327-336)*. Elsevier. DOI: 10.1016/S0072-9752(08)01916-7.

Tsao, C. W. vd. (2022). Heart Disease and Stroke Statistics-2022 Update: A Report From the American Heart Association. *Circulation*, 145(8), e153–e639. <https://doi.org/10.1161/CIR.0000000000001052>.

Turing, A. M. (1950) Computing Machinery and Intelligence. *Mind* 49: 433-460.

Türk Börü, Ü. vd. (2018). Stroke prevalence among the Turkish population in a rural area of Istanbul: A community-based study. *SAGE Open Medicine*, 6, 2050312118797565. <https://doi.org/10.1177/2050312118797565>.

Uçkun, S., Ağralı, M., & Kılıç, V. (2023). Deep Learning-Based Ischemic Stroke Segmentation on Brain Computed Tomography Images. *Avrupa Bilim Ve Teknoloji Dergisi*, 50(105-112). <https://doi.org/10.31590/ejosat.1258247>.

Vachha, B. A., & Schaefer, P. W. (2015). Imaging Patterns and Management Algorithms in Acute Stroke: An Update for the Emergency Radiologist. *Radiologic Clinics of North America*, 53(4), 801-826, ix. DOI: 10.1016/j.rcl.2015.02.012.

Van Everdingen, K. J. vd. (2006). ITK-SNAP: A Software Tool for Segmenting and Visualizing Multimodal Biomedical Imagery. *Medical Image Analysis*, 10(2), 280-291.

Vilela, P., & Rowley, H. A. (2017). Brain ischemia: CT and MRI techniques in acute ischemic stroke. *European Journal of Radiology*, 96, 162-172. [doi:10.1016/j.ejrad.2017.08.014](https://doi.org/10.1016/j.ejrad.2017.08.014).

Vymazal, J., Rulseh, A. M., Keller, J., & Janouskova, L. (2012). Comparison of CT and MR imaging in ischemic stroke. *Insights Imaging*, 3(6), 619–627. <https://doi.org/10.1007/s13244-012-0185-9>.

West, D. M. (2018). The Future of Work: Robots, AI, and Automation. *Washington, DC: Brookings Institution Press*.

Yıldız, Z., Gül, H. L. & Türk Börü, Ü. (2013) İskemik inmede metabolik sendromun sıklığı ve mortaliteye etkisi. *Türk Beyin Damar Hastalıkları Dergisi*, 19 (3): 88-94. DOI: 10.5505/tbdhd.2013.69875.

Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., & Liang, J. (2018). UNet++: A Nested U-Net Architecture for Medical Image Segmentation. Arizona State University. *Published in Deep Learn Med Image Anal Multimodal Learn Clin Decis Support*, September 2018, 11045: 3–11. [doi:10.1007/978-3-030-00889-5_1](https://doi.org/10.1007/978-3-030-00889-5_1).

Zhu, H., Jiang, L., Zhang, H., Luo, L., Chen, Y., & Chen, Y. (2021). An automatic machine learning approach for ischemic stroke onset time identification based on DWI and FLAIR imaging. *NeuroImage: Clinical*, 31, 102744. <https://doi.org/10.1016/j.nicl.2021.102744>.

Açık kaynaklı web sitesinden alınmıştır. Krankheitsbild: Ischämischer Schlaganfall (Klinik tablo: İskemik inme). [Erişim: 18.01.2024, <https://www.mediclin-hedon-klinik.de/fachbereiche-krankheitsbilder/krankheitsbilder-a-z/ischaemischer-schlaganfall/>]

Açık kaynaklı web sitesinden alınmıştır. Brain health. World Health Organization. [Erişim: 26.01.2023, https://www.who.int/health-topics/brain-health#tab=tab_1]