

**BEYİN MR TARAMALARINDAN İSKEMİK İNME LEZYONLARININ U-NET
TABANLI DERİN ÖĞRENME MİMARİSİ KULLANILARAK OTOMATİK
TESPİTİ**

**AUTOMATED DETECTION OF ISCHEMIC STROKE LESIONS USING U-NET
DEEP LEARNING ARCHITECTURE IN BRAIN MR SCANS**

Merve BALABAN

Yüksek Lisans Öğrencisi, Bilecik Şeyh Edebali Üniversitesi Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Gökhan UÇAR

Arş. Gör. Dr., Bilecik Şeyh Edebali Üniversitesi Mühendislik Fakültesi Bilgisayar
Mühendisliği Bölümü

Emre DANDIL

Doç. Dr., Bilecik Şeyh Edebali Üniversitesi Mühendislik Fakültesi Bilgisayar
Mühendisliği Bölümü

(Sorumlu Yazar)

ÖZET

Beyinde kan akışının kesilmesi sebebiyle gelişen inme hastalığı sebebiyle her yıl çok fazla insan yaşamını yitirmektedir. Bunun yanında, inme nedeniyle beyinde oluşan hasarlardan dolayı da birçok insanda fiziksel ve bilişsel bozukluk şeklinde kalıcı hasarlar oluşmaktadır. Bu sebeple hastanın hastaneye başvurduğu ilk evrede inmenin hızlı bir şekilde teşhis edilmesi ve doğru tedaviye başlanması büyük öneme taşımaktadır. İnmeden etkilenen beyin bölgelerinin ayırt edilme süreci nitelikli uzman görüşlerini gerektirmektedir. Ancak, uzmanların el yordamı ile bölütleme işlemleri zaman alıcı, hataya eğilimli ve subjektif süreçler içermektedir. İnme vakalarında ilk birkaç saatin hayati önem taşıdığı göz önünde bulundurulduğunda, tedavi sürecinin gecikmesi daha fazla beyin dokusunun yok olma tehlikesini ortaya çıkarmaktadır. Bu durum, iskemik inme lezyonunu bölütleyen ve tedaviye geçişi hızlandıran otomatik yöntemlere duyulan ihtiyacı göz ardı edilemeyecek hale getirmektedir. Son yıllarda, derin öğrenme ağları sayesinde uzman hekimlerin bölütleme ve karar verme sürecini hızlı ve başarılı bir şekilde yapabilmesini sağlamaya yönelik çalışmalar artmış ve bu çalışmalarda elde edilen performans seviyeleri de artmaya başlamıştır. Bu çalışmada, beyin Manyetik Rezonans (MR) görüntülerinden iskemik inme lezyonlarını otomatik bir şekilde bölütleyen ve tespit eden bir yöntem önerilmektedir. Çalışmada, lezyonların bölütlenmesi için hızlı bir eğitim sürecine sahip olan U-Net derin öğrenme mimarisi kullanılmıştır. Ayrıca, çalışmada iskemik inme teşhisi konmuş vakaların MR görüntülerini içeren global bir veriseti olan Ischemic Stroke Lesion Segmentation (ISLES) 2022 inme veriseti kullanılmıştır. Bu verisetinde iskemik inme teşhisinde hasar gören beyin dokularının hassas bir şekilde görüntülenmesini sağladığı için difüzyon-ağırlıklı MR görüntüleri (DAG) tercih edilmiştir. Deneysel analizlerde, 250 hastaya ait MR görüntüleri ile eğitilen U-Net derin öğrenme ağı kullanılarak F1, Dice ve Kesinlik (Precision), Duyarlılık (Recall) anahtar performans metrikleri için sırasıyla 0.85, 0.79, 0.86 ve 0.87 skorları başarılmıştır. Deneysel çalışmalarda elde edilen sonuçlar, ISLES 2022 katılımcılarının elde ettiği sonuçlarla örtüşüğü ve sonuç olarak U-Net derin öğrenme ağı ile oluşturulan modelin, iskemik inme lezyonlarını başarılı bir şekilde bölütleme ve teşhis etme potansiyeline sahip

olduğunu göstermiştir. Önerilen yöntemin uzman hekimlerin inme teşhisini kolaylaştıracağı ve karar verme aşamasında kullanabilecekleri yardımcı bir araç olabileceği değerlendirilmektedir.

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

ABSTRACT

Many people die each year from strokes, which occur when blood flow to the brain is interrupted. In addition, many people suffer permanent damage in the form of physical and cognitive impairment as a result of brain damage caused by a stroke. This is why it is so important to diagnose stroke quickly and start the right treatment in the first phase when the patient is admitted to hospital. The process of distinguishing the brain regions affected by stroke requires qualified expert opinion. However, manual segmentation by experts is time-consuming, error-prone and subjective. Given that the first few hours after a stroke are critical, delayed treatment carries the risk of further brain tissue destruction. The need for automated methods to segment the ischemic stroke lesion and accelerate the transition to treatment is therefore imperative. In recent years, deep learning networks have been used to enable expert physicians to perform segmentation and decision-making processes quickly and successfully, and the performance levels achieved in these studies have started to increase. In this study, we propose a method to automatically segment and detect ischemic stroke lesions from brain magnetic resonance (MR) images. The U-Net deep learning architecture with a fast training process is used for lesion segmentation. In addition, the study uses the Ischemic Stroke Lesion Segmentation (ISLES) 2022 stroke dataset, a global dataset containing MR images of cases diagnosed with ischemic stroke. In this dataset, diffusion-weighted MR images (DWI) are preferred for the diagnosis of ischemic stroke as they provide precise visualization of damaged brain tissue. In the experimental analyses, using the U-Net deep learning network trained on MRI images from 250 patients, scores of 0.85, 0.79, 0.86 and 0.87 were achieved for the key performance metrics F1, Dice, Precision and Recall, respectively. The results obtained in the experimental studies are consistent with the results obtained by the ISLES 2022 participants, and as a result, the model built with the U-Net deep learning network has the potential to successfully segment and diagnose ischemic stroke lesions. It is anticipated that the proposed method can facilitate stroke diagnosis for specialist physicians and can be a helpful tool for them to use in the decision-making phase.

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

1. GİRİŞ

Bedenin yönetim merkezi olarak bilinen beynimiz, hayati işlevlerin devam ettirilmesinde önemli rol oynar. Beyinde oluşan anormal durumlar yaşamsal faaliyetlerin aksamasına ve yaşam kalitesinin düşmesine sebep olabilmektedir. Beyin damarlarında biriken yağ parçacıkları veya pıhtıların yol açtığı daralma veya tıkanmaya bağlı olarak kan akışındaki düzensizlik, yetersizlik veya kan akışının engellenmesi iskemi olarak adlandırılan beyin dokusunun oksijenden yoksun kalmasına neden olmaktadır. Damarların aniden tıkanması kısaca enfarktüs durumunun uzun süreli devam etmesi beyin dokusunun ölümüyle sonuçlanmaktadır ve bu durum iskemik inme olarak bilinmektedir [1]. İnme, en yaygın ölüm sebeplerinden olmakla birlikte kol ve bacaklarda güçsüzlük, konuşma ve yutma zorluğu, düşünel faaliyetlerin yapılamaması, hafıza kaybı gibi insan yaşamının bütünlüğünü önemli ölçüde etkileyecek geçici veya kalıcı kayıplara da sebep olmaktadır. 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 [2-5]. İnme durumunda tedaviye karar verme süreci önemlidir, teşhisin bir an önce yapılması ve uygun tedaviye başlanması hayati riski ve fonksiyon kaybını en aza düşürmede etkili olduğu bilinmektedir [6].

Manyetik Rezonans Görüntüleme (MRG), beynin hastalık teşhisinde kullanılabilecek bir görüntüsünü oluşturmak için güçlü radyo dalgaları ve mıknatıslar kullanır. İskemik inme vakalarının tespitinde zarar gören beyin dokusunu tespit amacıyla kullanılan en etkili yöntemlerdendir. Manyetik Rezonans (MR) görüntüleri, diğer tıbbi görüntüleme yöntemlerine göre sunduğu daha yüksek kalitedeki görüntüler ve zarar gören dokunun konumu, şekli, büyüklüğü gibi özelliklerini daha iyi gösterebilmektedir [7,8]. Ancak, MR görüntülerinin yorumlanması ve analiz edilmesi hem zor hem de zaman alana bir süreç olmasının yanı sıra uzmanların da gözden kaçırabildiği detaylara sahip olabilmektedir [9]. Bu durum aynı vakaya ait görüntüleme yorumlarının radyologlar arasında farklılık göstermesine sebep verebilmektedir.

Gelişen teknoloji ile birlikte, iskemik inme vakalarında teşhis ve tedaviye geçişi hızlandıran yüksek teknolojik yöntemler ile hızlı ve daha fazla doğruluğa sahip sonuçlar alınabilmektedir [10]. Son yıllarda, sağlık alanında büyük rol oynayan yapay zeka destekli tıbbi görüntü bölütleme yöntemleri sayesinde iskemik inme tespiti ve analizi kolaylıkla yapılmaya ve verimli sonuçlar alınmaya başlanmıştır [11-13]. Bilgisayarlara verileri insan beyninden esinlenerek işlemeyi sağlayan yapay zekâ tekniklerinden derin öğrenme modelleri, doğru öngörü ve tahminler üretmek için resimler, metinler, sesler ve diğer verilerdeki karmaşık modelleri tanıyabilir.

Derin öğrenme modellerinden tıbbi görüntü bölütleme özelinde geliştirilen U-Net mimarisi, farklı seviyelerdeki özellikleri birleştirerek hassas bölütleme yeteneğine sahiptir [14]. İnme vakalarının teşhisinde, çoğunlukla kontrastlı görüntüler içeren taramaların kullanılması ve bunların detaylı bir analize ihtiyaç duyması dolayısıyla bölütleme işlemlerinde U-Net'in hassasiyetinin etkili olması beklenmektedir. U-Net modeli veri sayısının sınırlı olmasını göz ardı edebilecek ve az sayıda veriyle hızla öğrenebilecek şekilde tasarlanmıştır. Çalışmanın odağında bulunan inme bölütlemesinde olduğu gibi çoğu araştırmacı için ulaşılabilecek sınırlı kaynakların olması U-Net'in tercih edilirliliğini artırmaktadır [15-19].

MR taramalarında özellikle Difüzyon Ağırlıklı Görüntüleme (DAG) yönteminin kullanımının iskemik inme durumlarında öne çıktığı görülmektedir [20,21]. Difüzyon MR olarak da bilinen bu yöntem beyin dokusunun yapısındaki mikro değişimlerin gözlemlenmesine odaklanmaktadır. Beyin dokusundaki anormalliklerin fark edilmesi için su moleküllerinin difüzyon hızındaki değişimleri ölçebilme kapasitesine sahiptir. Ayrıca DAG yöntemi ile

iskemik inmenin hasar verdiği dokunun bölgesel yerini ve farklı evrelerini belirlemede önemli bilgiler taşıyan farklı kontrastlardaki görüntüler yüksek çözünürlükte elde edilebilmektedir.

İnme hastalığının teşhisi için literatürde daha önce birçok çalışma önerilmiştir. Bu çalışmaların birisinde, Ehab vd. [15] çalışmalarında, tıbbi görüntü segmentasyonunda derin öğrenme modellerinin, özellikle de UNet mimarisinin kullanımını araştırmışlardır. Çalışmada, görüntü normalleştirme, yeniden boyutlandırma, mimari seçimler, kayıp fonksiyon tasarımı ve hiperparametre ayarlama gibi çeşitli görevlerdeki performans değerlendirmesi yapılmıştır. Sonuçlar standart U-Net modelinin yetkin olduğunu, ancak Res-UNet ve Attention Res-UNet mimarilerinin üstün performans gösterdiğini ortaya koymuştur. Bir diğer çalışmada ise, Kadry vd. [16], ISLES 2015 veri seti üzerinde U-Net mimarisini kullanarak beyin MR dilimlerinde İskemik İnme Lezyonunun (ISL) tespitine odaklanmışlardır. Çalışmada, beyin MRG dilimlerinden ISL parçalarını çıkarmak için önceden eğitilmiş bir U-Net kodlayıcı-kod çözücü sistemini kullanılmıştır. Sonuçta, 20 hastanın 500 kesitine dayanan gerçek veriler ve çıkarılan lezyonların karşılaştırılmalı değerlendirmesi gerçekleştirilmiştir. Önerilen şema, beyin anormalliklerini tespit etmede başarılı olmuş ve sorunun yeri ve ciddiyeti hakkında değerli bilgiler sağlamıştır. Polat vd. [17] ise çalışmalarında, beyin inmesi (stroke) tespiti ve segmentasyonu için Res2Net omurgalı U-Net derin öğrenme modelini kullanmışlardır. Toplam 2223 BT görüntüsü içeren veri seti, 1093 hemorajik ve 1130 iskemik inme tipini kapsamaktadır. Görüntüler pencereleme yöntemi ile ön işlemden geçirilmiş ve ardından önerilen model ile eğitilip test edilmiştir. Test sonuçları, uygun pencere ayarlarının kullanılmasının segmentasyon performansını artırdığını göstermiştir.

Uçkun vd. [18] çalışmalarında, iskemik inmeyi otomatik olarak teşhis etmek için Bilgisayarlı Tomografi (BT) görüntülerinde segmentasyon yapmak üzere derin öğrenme tabanlı bir arayüz geliştirmişlerdir. Çalışmada, derin öğrenme modellerinin, iskemik inme segmentasyonunda otomatik özellik çıkarma olanağı sağladığı ortaya koyulmuştur ve BT görüntülerinde hastalık bölgelerini işaretlemek için bu modeller kullanılmıştır. U-Net, U-Net VGG16, U-Net VGG19, Attention U-Net ve ResU-Net gibi mimariler, iskemik inme hastalık segmentasyonunu karşılaştırmak için kullanılmıştır. Modifiye ResU-Net, iskemik inme segmentasyonunda en yüksek performansı sağlamıştır. Bu modifiye mimari, BrainSeg adlı yeni bir masaüstü uygulamasına entegre edilerek uzmanlara iskemik inme teşhisi konusunda destek sunması öngörülmüştür. Liyuan vd. [22], iskemik inme tespiti için yapay zeka uygulamalarının kullanımının, tedavi seçeneklerini ve klinik sonuçları artırma potansiyeli bulunduğunu belirtmişlerdir. Ancak, derin öğrenmenin iskemik inme teşhisi için hala bazı zorluklarla karşılaştığı ve gelecekte daha geniş kullanım için doğrulama çalışmalarına ihtiyaç duyulduğu vurgulanmıştır. Yanı sıra, derin öğrenme yaklaşımlarının yorumlanabilirlik eksikliği ve radyologların güven konusundaki şüpheleri üzerinde durulmuştur. Çalışma sonucunda, yapay zeka çözümlerinin tahmin doğruluğunu artırmaya odaklanmanın yanında, bu tahminleri yorumlama yeteneğinin de geliştirilmesinin klinik uygulanabilirlik ve kabulü artırabileceği belirtilmiştir. Chen vd. [23], akut iskemik lezyonları otomatik olarak tespit etmek amacıyla DAG görüntülerinde lezyonları bölütleme için iki evrişimli sinir ağı (CNN) içeren bir çerçeve önermişlerdir. EDD Net ve MUSCLE Net adlı iki CNN'nin birleşimi olarak geliştirilen yöntem, büyük bir klinik veriseti üzerinde test edilmiş ve 741 hasta verisinde ortalama lezyon tespit oranı elde etmiştir. Gelecekte, bu yöntemin geliştirilmesi için daha fazla DAG görüntüsü toplanarak eğitim ve test setlerinin genişletilmesi ve çerçevenin geliştirilerek uçtan uca kullanıma uyarlanması önerilmiştir. Taşçı [24], yaptığı çalışmada DAG görüntülerinden akut iskemik inme teşhisi yapılabilmesi için bir model geliştirmeyi hedeflemiştir. Çalışma kapsamında, 1112 akut iskemik infarktüs ve 1202 normal difüzyon MR görüntüsü içeren 4 farklı veri seti kullanılmıştır. Önceden eğitilmiş ağırlıklar kullanabilen CNN modelleri ile elde edilen özellikler, Destek Vektör Makineleri (SVM) ile sınıflandırılmış ve bulunan tahmin vektörleri Iterative Majority Voting (IMV) yöntemine tabi tutulmuştur.

Değerlendirme sonuçlarına göre, akut iskemik inme sınıflandırma modelinin yüksek başarımlara sahip olduğu görülmüştür.

Bu çalışmada, biyomedikal görüntü işlemede özelleştirilmiş derin öğrenme modellerinden U-Net ile MR görüntülerindeki iskemik inme lezyonlarının tespitinde kullanımı incelenmiş ve analizleri yapılmıştır. Çalışma kapsamında, ISLES'22 Akut ve Sub-akut İnmede Multimodal MRG Enfarktüs Segmentasyonu [25] veri setindeki iskemik hasarın en iyi gözlemlendiği DAG görüntüleri ile uzmanlar tarafından etiketlenmiş maske görüntüleri kullanılmaktadır. ISLES'22 veriseti hastalığın erken teşhisinden ileri düzeydeki durumlara kadar çeşitli senaryoları kapsayan farklı lezyon boyutu, karmaşık enfarktüs örüntüleri gibi geniş bir spektruma sahiptir. Çalışmada kullanılan modelden elde edilen sonuçlar için Dice benzerlik katsayısı (Dice), F1-skor (F1-score), duyarlılık (Recall), kesinlik (Precision) ve doğruluk (Accuracy) değerleri hesaplanmıştır. Çalışmanın sonraki bölümlerinde, çalışmanın literatürdeki yerine değinilmiş ve kullanılan verisetinin detaylarına yer verilmiştir. Ardından, çalışmada sunulan U-Net mimarisinin altyapısı ve önerilen derin öğrenme mimarisinden bahsedilmektedir. Son bölümde yapılan deneysel analizin bulgularına ve çıkarılan sonuçlara değinilirken çalışmanın geleceği değerlendirilmektedir.


2. MATERYAL ve YÖNTEM

Derin öğrenme, yapay sinir ağlarını kullanarak bilgisayar sistemlerinin öğrenme süreçlerini, insan beyninin karmaşık yapısını taklit ederek gerçekleştirmeye odaklanan bir makine öğrenimi alt alanıdır. Yapay sinir ağları, sinir hücrelerinin biyolojik benzerlikleri ile bilgi işleme ve öğrenme yeteneklerine benzeyen karmaşık bir yapıya sahiptir. Derin öğrenme, bu yapay sinir ağlarının katmanlar arasındaki bağlantıları güçlendirmek ve genelleştirmek için öğrenme yeteneklerini optimum düzeye taşımayı amaçlamaktadır. Bu sayede derin öğrenme modelleri, özellikle büyük veri setlerinde karmaşık desenleri tanıma, sınıflandırma ve tahmin etme konularında insan benzeri performans sergileyebilirler. Derin öğrenme modelleri, tıbbi görüntü analizi gibi büyük ve karmaşık veri setlerine sahip alanlarda derinlemesine analiz yapma yeteneği sayesinde önemli başarılar elde etmiştir. Derin öğrenme modelleri, önceden işlenmiş veri setlerinde eğitim alarak mevcut veriden karmaşık modelleri öğrenerek inme lezyonlarını doğru bir şekilde segmentlere ayırabilir [26]. İskemik inme segmentasyonu için de çeşitli derin öğrenme yöntemleri, özellikle evrimsel sinir ağları kullanılmaktadır. Bu yöntemler, BT veya MRG taramalarından iskemik inme lezyonlarının ayırt edilmesinde doğruluğu yüksek sonuçlar elde edebilmektedir. Biyomedikal taramalardaki teşhis süreci manuel işlemlere ve uzmanlara ihtiyaç duyduğu için hem zaman alıcı hem de yoğun dikkat isteyen bir aşamadır. Tıbbi görüntü segmentasyonunda derin öğrenme yöntemlerinin kullanılması, sürecin otomatikleştirilip yüksek doğrulukta ve verimli sonuçlar elde edilmesine imkan tanımaktadır. CNN modelleri zaman içerisinde önemli gelişmeler geçirmiş ve performanslarını çeşitli yönlerden geliştirmişlerdir. İlk mimarilerden olan Neocognitron[27] ve LeNet-5[28] sınırlı sayıda katmana sahip olmasına rağmen AlexNet[29], VGG[30], GoogLeNet[31], ResNet[32] ve DenseNet[33] gibi modeller, daha karmaşık yapı ve katman derinliği sunmaktadır. Bu ağlar, aktivasyon fonksiyonu olarak sigmoid ve tanh kullanan eski mimarilere göre ReLU kullanımını kabul ederek birlikte öğrenmenin iyileştirilmesiyle birlikte eğitim sürecinin hızlanmasına da olanak tanımıştır.


2.1. Veriseti

Bu çalışmada kullanılan veri seti, ISLES'22 İskemik İnme Lezyon Bölütleme Challenge kapsamında Akut ve Sub-akut İnmede Multimodal MRG Enfarktüs Segmentasyonu (Multimodal MRI Infarct Segmentation in Acute and Sub-Acute Stroke) alt görevi için yayınlanan çeşitli iskemik inme vakalarını içeren görüntülerden oluşmaktadır [22]. Bu çalışmada kullanılacak olan modelde girdi olarak kullanılan DAG sekansı için örnek görüntüler Şekil 1'de verilmiştir.

Verisetindeki MRG taramaları, ADC, DWI ve FLAIR sekanslarında görüntüleri içerir. Verisetinde yer alan 250 vakanın MR görüntüleri tüm sekanslar için Nörogörüntüleme Bilişim Teknolojisi Girişimi (NİFTI) formatında kaydedilmiştir. Her tarama axial düzlemde 112*112 orjinal piksel boyutundaki 72 MR diliminden oluşmaktadır. Etiketleme işlemleri, DWI (DAG) sekansı baz alınarak Münih Üniversite Hastanesi'nden alınan verilerle eğitilen bir algoritma, bütün segmentasyonları kontrol edip aynı zamanda etiketleri hazırlayan bir tıp öğrencisi ve maske ve etiketlemeleri inceleyen inme görüntüleme uzman nöroradyologlar ile uygulanan İnsan-Algoritma etkileşimli bir şema kullanılmıştır. Klinik aşamaların iyileştirilmesine yönelik bir imkan sunmak adına taramalarda elde edilen görüntüler işlenmemiş olarak bırakılmıştır. Görüntüler üzerinde sadece beyin MR görüntülerinden baş ve boyun bölgesinin segmentasyonunu gerçekleştiren bir derin öğrenme modeli olan HD-BET (Head and Neck Deep Learning Brain Extraction Tool) [34] kullanılarak görüntülerde kafatası soyuma işlemi gerçekleştirilmiştir. Verisetinde bulunan MRG modaliteleri için örnek görüntü ve uzman bölütlemesi Şekil 2'de verilmiştir.



Şekil 1. ISLES'22 Akut ve Sub-Akut İnmede Multimodal MR Enfarktüs Segmentasyonu verisetinden lezyon içeren örnek difüzyon MR görüntüleri

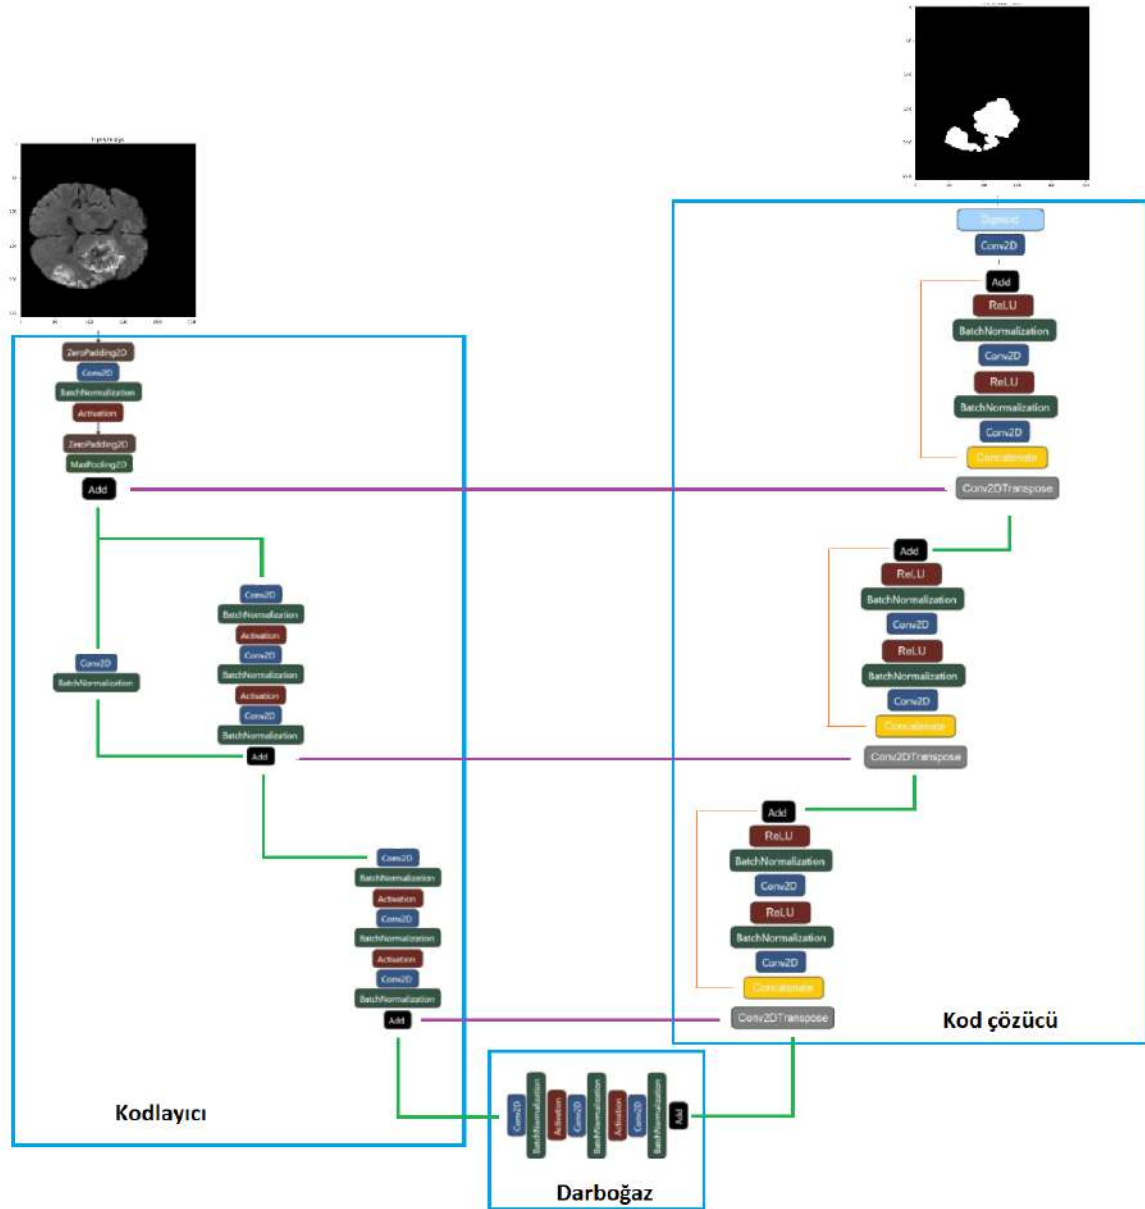


Şekil 2. ISLES'22 Akut ve Sub-Akut İnmede Multimodal MR Enfarktüs Segmentasyonu verisetinin farklı MR sekans görüntüleri ve anatomik düzlemlerdeki uzman etiketlemeleri örneği

2.2. Önerilen Yöntem


U-Net algoritmasının mimarisi, U şeklindeki daralan ve genişleyen yapısıyla karakterize edilir. Her blok, segmentasyon görevinde belirli bir amaca hizmet eder. Kodlayıcı bloğu (encoder), giriş görüntüsünün alt örneklemeinden hiyerarşik özelliklerin yakalanmasından sorumlu evrişimli bloklardan (convolutional block) oluşur. Evrişimli bloklar, batch normalizasyonu ve ReLU aktivasyonuna sahip iki evrişimli katman içerir. Sonrasında örneklerdeki uzamsal boyutları azaltmak için maksimum-havuzlama (max-pooling) aşaması bulunur. U şeklinin alt kısmını temsil eden darboğaz, kodlayıcıyı ve kod çözücü (decoder) birbirine bağlar [14]. Giriş görüntüsündeki en soyut özellikleri kompakt bir biçimde yakalar ve böylece kod çözücü bloğunda istenen çıktıyı yeniden oluşturmak için bu üst düzey anlamsal bilgilerin kullanılmasına olanak tanır. Darboğazın kullanımı, özellik haritalarının boyutsallığını azaltması sayesinde kritik özellikleri korumak ve ağ hesaplamasında kullanılan sınırlı kaynaklar düşünüldüğünde tercih edilmektedir. Darboğazı, kod çözücü blokları takip eder. Düşük çözünürlüklü özellik haritalarını orijinal giriş boyutuna kadar yukarı örneklemeden sorumludur. Evrişim işlemlerini uygulayarak son segmentasyon maskesini oluşturur. Kod çözücü bloklar, batch normalizasyonu ve ReLU aktivasyonuna sahip iki evrişimli katmana sahiptir. ReLU aktivasyonu, piksel bazında ikili tahminler üretmek için sigmoid aktivasyonunun uygulandığı çıkış katmanını hariç, ağ genelinde kullanılır. U-Net mimarisinin çıkış katmanını ise, segmentasyon maskesini üretmek için sigmoid aktivasyon fonksiyonuna sahip 1x1 evrişimli katman kullanır.

Çalışma kapsamında U-Net ile iki farklı ağ modeli birleştirilmiştir. Önerilen ilk bölütleme modeli olan ResNet50 [35] ile birleştirilmiş U-Net modeli, iki mimarinin de gücünden yararlanmayı amaçlanmıştır. Model, solda bir kodlayıcı blok ve sağda bir kod çözücü blok içeren U-Net mimarisi üzerinde geliştirilmiştir. ResNet50'nin derin evrişimli katmanları çok sayıda özellik çıkarımına olanak verir. Bu sayede, U-Net mimarisine segmentasyon görevleri için bilgi ve özellik bakımından zengin bir temel sağlanabilir. Şekil 3'te gösterildiği gibi, orijinal U-Net'in kodlayıcı kısmı ResNet50 ile değiştirilmiş ve daha derin bir ağ eğitme olanağı elde edilmiştir. ResNet50 modelinin, geniş bir nesne sınıflandırma veri seti olan ImageNet üzerinde önceden eğitilmiş ağırlıkları kullanması, özellikle sınırlı veri setlerinde model eğitiminin verimini artırabilmektedir. Önerilen model, ResNet50'yi değiştirilmiş U-Net mimarisi bağlamında kullanırken, bu ağın bir parçası olarak giriş görüntüsünden hiyerarşik özellikler çıkaran bir kodlayıcı (encoder) olarak görev yapmaktadır.



Şekil 3. ResNet50 ile birleştirilen U-Net modelinin diyagramı

Önerilen ikinci model VGG19 [30] ile birleştirmiş U-Net modeli, VGG19'un basit ve simetrik yapısından yararlanmaktadır. VGG19'un büyük verisetleriyle önceden eğitilmiş olması sayesinde transfer öğrenme ile daha küçük verisetleri üzerinde daha iyi özellik çıkarımı sağlayabilir. Çok katmanlı ağ yapısı ile giriş görüntüsünden farklı düzeylerde özellikleri haritalandırabilir. Ağdaki evrişim katmanları 3x3 gibi küçük filtreler kullandığı için etkili bir özellik öğrenme ortamı sunar. Katmanlarda değişiklik yapabilme ve konvolüsyon ve pooling işlemlerini kolaylaştırmasının yanı sıra hiyerarşik öğrenme yeteneği bu çalışmada önemlidir. Önerilen modelde, VGG19, U-Net mimarisinin kodlayıcı kısmında kullanılmıştır. Derin öğrenme ve sinir ağları için görsel modelleme imkanı sunan Netron [36] modülü ile üretilmiş VGG19_UNet modeli diyagramı Şekil 4'de verilmiştir.



Şekil 4. Netron ile üretilmiş VGG19_UNet modeli diyagramı

3. DENEYSEL BULGULAR

Bu çalışmada, MRG tarama verileri üzerinde iskemik inme segmentasyonunu U-Net modeli ile gerçekleştirebilen, segmentasyon işleminde verinin hazırlık aşamasını kolaylaştıran bir ortam geliştirilmiştir. Görüntü segmentasyonu için geliştirilecek nöral ağ modeli için veri seti eğitim, test ve doğrulama setlerine bölündükten sonra encoder olarak ResNet50 mimarisinin kullanıldığı U-Net modeli ve encoder olarak VGG19 mimarisinin kullanıldığı U-Net modeli oluşturulmuştur. Bir eğitim iterasyonunda kullanılan veri örneklerinin sayısı olan batch boyutunun büyük olması daha az bellek kullanımını ve modelin daha kararlı bir şekilde öğrenmesini sağlayabilir. Bu çalışmada batch boyutu, daha güncel ve hızlı bir öğrenme olanağı sunması açısından eğitim kümesi için 8, test ve doğrulama kümeleri için 4 olarak belirlenmiştir. Önerilen model 100 ve 150 epok (tur) için eğitilmiştir. Optimizasyon algoritması olarak Adam optimize ediciyi öğrenme oranını 0.001'den başlatılarak düşük öğrenme oranı geri araması ile kullanılmıştır. Modelin eğitiminde doğrusal olmayan aktivasyon fonksiyonu olarak ReLU tercih edilmiştir. Modelin çıkış katmanında sigmoid aktivasyon fonksiyonu kullanılmıştır. Ayrıca, modelin değerlendirilmesi için kayıp fonksiyonları olarak ikili çapraz entropi, Dice katsayısı ile derlenmiş ve test kümesi üzerinde doğruluk, kesinlik, duyarlılık, F1-skor gibi metriklerde performansı ölçülmüştür. Bu şekilde, sadece kafatası soyma (skull stripping) işleminden geçmiş ham veriye medikal görüntü segmentasyonu uygulamak için oldukça kapsamlı ve özelleştirilebilir bir temel oluşturulmuştur. Önerilen U-Net modelleri için kullanılan eğitim parametreleri ve değerleri Tablo 1'de verilmiştir.

Tablo 1. Önerilen U-Net modellerinin eğitim parametreleri ve değerleri

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

Önerilen modellerde batch normalizasyonu ve ReLU aktivasyonu ile evrişimli bir blok tanımlanmıştır. Aktivasyonları normalleştirmek için her evrişim katmanından sonra batch normalleştirme uygulanır. Bu sayede eğitim kararlılığının sağlanması hedeflenmiştir. Yukarı örnekleme için birleştirme ve evrişimli katmanlara sahip bir kod çözücü bloğu tanımlanmıştır. Önceden ImageNet veriseti ile eğitilmiş ResNet50 ve VGG19 modelleri kodlayıcı bloğunda kullanılmış ve farklı VGG19 katmanlarından ara özellik haritalarını çıkartılmıştır. U-Net modelinin kod çözücü kısmında segmentasyon maskesini elde etmek için son evrişimli katmanın çıktıları için sigmoid aktivasyon fonksiyonu kullanılmıştır.

Bu çalışmada, derin öğrenmesi yöntemlerinden U-Net modeli oluşturma ve bahsi geçen veri seti kullanılarak iskemik inme lezyonlarının segmentasyonu amaçlanmıştır. ISLES'22 veriseti 250 vakaya ait 3 farklı sekanstaki MRG taramalarından oluşmaktadır ve bu çalışmada DAG sekansındaki görüntüler tercih edilmiştir. İskemik inme vakalarında lezyonların felçten hemen sonra görüntülenmesini mümkün kılan suyun bölgesel hareketine odaklanan difüzyon

MR yöntemi, serebral infarktın erken dönem teşhisini kolaylaştıracak hassasiyete sahip olduğu için daha çok kullanılmaktadır. Görüntüler sıkıştırılmış .nii formatından nibabel kütüphanesi ile orjinal boyutlarında (112x112 piksel) olarak PNG formatında çıkartılmış ve aksiyel (axial) düzlemde toplam 15731 görüntü elde edilmiştir. İlk aşamada, eğitim öncesinde görüntülerden uzman maskesi taşımayanlar ayıklanmış ve kalan 4.827 görüntü belirli bir boyutta (256x256 piksel) yeniden ölçeklendirilmiştir. İkinci aşamada, değerlendirmeler sonucunda başarıyı düşürdüğü belirlenen MR tarama başlangıcı ve sonuna denk geldiği için yeterli maskeye sahip olmayan veya hiç olmayan görüntüler ayıklandıktan sonra 4193 görüntü ile performans testler gerçekleştirilmiştir.

Veri hazırlama aşaması manuel işlemler yerine otomatik bir hale getirilmiş ve önerilen U-Net modeli ile eğitimler gerçekleştirilmiştir. Modelde kullanılan hasta verilerinden rastgele seçilecek şekilde eğitim kümesi %87, test kümesi %3 ve doğrulama kümesi %10 olarak ayrılmıştır. Model 112x112 piksel ve 256x256 piksel görüntülerle eğitilmiştir. Çalışmada önerilen modelin eğitimi ortalama 7 saat sürmüştür. Çalışmada iskemik inme segmentasyonu üzerine önerilen tüm modellere, Jupyter Notebook 6.5.4 çalışma ortamında Python 3.11.4 yazılım dili kullanılarak, arka uç olarak Tensorflow Keras 2.10.0 çerçevesinde Intel® Core™ i7-12700H CPU, 32 GB bellek ve NVIDIA RTX 3060 GPU bileşenine sahip bir bilgisayar kullanılarak veri hazırlama ve eğitim aşamaları uygulanmıştır.

İskemik inme segmentasyonunu değerlendirmek için segmentasyon 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 (1), Eşitlik (2), Eşitlik (3), Eşitlik (4) ve Eşitlik (5)'te sunulmuştur. Doğrusal olmayan aktivasyon fonksiyonu olarak ReLU ve kayıp fonksiyonu olarak ikili çapraz entropi tercih edilmiştir ve Eşitlik (6)'da görülmektedir.

$$\text{Duyarlılık (DY)} = \frac{TP}{TP + FN} * 100 \quad (1)$$

$$\text{Doğruluk (DG)} = \frac{TN + TP}{TN + FP + TP + FN} * 100 \quad (2)$$

$$\text{F1 - skoru (F1)} = \frac{2 * DY * KS}{DY + KS} * 100 \quad (3)$$

$$\text{Dice katsayısı (Dice)} = \frac{2 * TP}{2 * TP + FP + FN} * 100 \quad (4)$$

$$\text{Kesinlik (KS)} = \frac{TP}{TP + FP} * 100 \quad (5)$$


$$\text{İkili Çapraz Entropi} = -y_1 \log(p_1) - (1 - y_1) \log(1 - p_1) \quad (6)$$

Tablo 2'de encoder (kodlayıcı) olarak ResNet50 mimarisinin kullanıldığı U-Net modeli için 4 farklı hiperparametre optimizasyonu ile elde edilen sonuçlar görülmektedir. Buna göre, en iyi

skorların batch boyutunun 8 ve epok sayısının 150 olduğu performans testinde elde edilmiştir. En iyi bölütleme testinde stroke lezyonlarının bölütlenmesinde önerilen yöntem ile Dice skoru için 0.79 ve F1 için 0.85 oranları başarılıdır. Ayrıca, en iyi performans testinde verisetindeki bazı kesitler için inme lezyonlarının önerilen yöntem ile başarılı bir şekilde bölütlenmesi Şekil 5'te görülmektedir.

Tablo 2. ResNet50 mimarisinin kullanıldığı U-Net modeli için performans sonuçları

Görüntü	Batch	Epok sayısı	İterasyon	Test süresi	Toplam eğitim	F1	Dice	KS	DY	Loss	DG
256x256	8	150	915	0.016	687.13	0.85	0.79	0.86	0.87	0.18	0.996
256x256	8	100	915	0.026	455.66	0.76	0.71	0.80	0.74	0.27	0.991
256x256	4	150	915	0.028	375.25	0.76	0.72	0.80	0.77	0.35	0.990
256x256	4	100	915	0.031	294.78	0.74	0.67	0.76	0.73	0.36	0.989




Şekil 5. ResNet50_U-Net'e göre bazı difüzyon MR kesitlerinin uzman tarafından bölütlenen gerçek maske ve iskemik inme segmentasyonu sonuçları

Diğer taraftan, Tablo 3'te görüldüğü gibi, encoder olarak VGG19 mimarisinin kullanıldığı U-Net modeli için batch boyutunun 8 ve epok sayısının 150 olduğu performans

değerlendirmesinde, Dice skoru için 0.77 ve F1 için 0.83 oranları başarılmıştır. Buradan, encoder (kodlayıcı) olarak ResNet50 mimarisinin kullanıldığı U-Net modeli kullanılarak, inme lezyonlarının daha başarılı bir şekilde tespit edildiği görülmektedir. Şekil 6'da ise encoder olarak VGG19 mimarisinin kullanıldığı U-Net modeli ile bazı lezyonlardaki bölütleme sonuçları sunulmuştur.

Tablo 3. Encoder olarak VGG19 mimarisinin kullanıldığı U-Net modeli için performans test sonuçları

Görüntü	Batch	Epok sayısı	İterasyon	Test süresi	Toplam eğitim	F1	Dice	KS	DY	Loss	DG
256x256	8	150	915	0.019	683.78	0.83	0.77	0.83	0.85	0.21	0.99



Şekil 6. VGG19_U-Net'e göre bazı difüzyon MR kesitlerinin uzman tarafından bölümlenen gerçek maske ve iskemik inme segmentasyonu sonuçları

4. SONUÇLAR

Bu çalışmada ResNet50 ve VGG19 tabanlı U-Net modelleri ile ISLES'22 kapsamında yayınlanan DAG MR tarama verileri üzerinde iskemik inme segmentasyonunu hassas bir şekilde gerçekleştirebilecek ve segmentasyon sürecinde veri hazırlama aşamasını kolaylaştıracak bir ortam geliştirilmiştir. ResNet50'nin eğitilmiş ağırlıkları transfer öğrenme yeteneklerinden faydalanarak, modelin iskemik inme segmentasyon görevinde daha genel ve etkili özellik haritaları çıkarılmıştır. VGG19 tabanlı U-Net modelinde ise, DAG sekansındaki çözünürlüğü yüksek beyin görüntülerinden iskemik lezyonlarını segmente etmedeki doğruluğu artırmak hedeflenmiştir. Çalışmada ilk önce, ResNet50 mimarisiyle önceden eğitilmiş ağırlıkları kullanılarak özellik çıkarımı yapılmıştır ve U-Net mimarisi ile birleştirilerek segmentasyon haritaları elde edilmiştir. Eğitim aşamasına geçildiğinde modelin

iskemik lezyonları doğru bir şekilde tanınması için hiperparametreler düzenlenmiştir ve verimin arttığı batch ve epok sayıları belirlenerek ayarlanmıştır. Performans testi aşamasında verisetinden ayrılan görüntülerde bölütleme işlemi gerçekleştirilmiştir ve değerlendirme metrikleri ve kayıp fonksiyonu ile sonuçlar ölçülmüştür. Daha sonrasında ResNet50 mimarisiyle en iyi sonuçların alındığı performans testleri, karşılaştırma için kodlayıcı olarak VGG19 mimarisi kullanılan U-Net modeli ile tekrarlanmıştır. Test prosedürlerinin uygulanmasının ardından iskemik inme lezyonlarının tespitinde elde edilen bulgular, çalışmada önerilen ResNet50_U-Net ve VGG19_U-Net modellerinin iskemik inme verileri üzerinde geliştirilebilecek bir performansa sahip olduğunu göstermektedir. Büyük lezyonların segmentlenmesinde performans oldukça iyi iken küçük lezyonlarda performansın düştüğü görülmektedir. Sonraki süreçte, U-Net modelinin farklı derin öğrenme modellerinin farklı bloklarda kullanım kombinasyonlarından oluşan deneysel çalışmaların yapılması ve sonuçların karşılaştırılması planlanmaktadır. Ayrıca, modelin klinik uygulamalarında kolay kullanılabilirlik kazanması için bu çalışmadaki gibi ham verisetlerinin doğrudan işlenmesini sağlayacak çalışmalara odaklanılacaktır. Gelecekteki çalışmalarda, modelin eğitilmesi için daha geniş ve daha fazla heterojen veri içeren, veri kümelerinin kullanılmasına, ve daha spesifik parametre ayarlarının uygulanmasına öncelik verilecektir.

TEŞEKKÜR

Bu çalışmada ISLES'22 İskemik İnme Lezyon Bölütleme Challenge kapsamında Akut ve Sub-akut İnmede Multimodal MRG Enfarktüs Segmentasyonu için hazırlanan verisetinin kullanımına izin verdikleri için organizatörlere ve katkı sağlayıcılara teşekkürlerimizi sunarız.

KAYNAKÇA

- [1]. Capriotti, Teri DO, MSN, CRNP; Murphy, Teresa SN. (2016). Ischemic Stroke. *Home Healthcare Now* 34(5):p 259-266, May 2016. Doi: 10.1097/NHH.0000000000000387.
- [2]. Andersen KK, Olsen TS, Dehlendorff C, Kammersgaard LP. Hemorrhagic and ischemic strokes compared: stroke severity, mortality, and risk factors. *Stroke*. 2009 Jun;40(6):2068-72. doi: 10.1161/STROKEAHA.108.540112. Epub 2009 Apr 9. PMID: 19359645.
- [3]. Campbell, B.C.V., De Silva, D.A., Macleod, M.R. et al. Ischaemic stroke. *Nat Rev Dis Primers* 5, 70 (2019). <https://doi.org/10.1038/s41572-019-0118-8>.
- [4]. 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>.
- [5]. Mozaffarian D, Benjamin EJ, Go AS, Arnett DK, Blaha MJ, Cushman M, American Heart Association Statistics Committee, Stroke Statistics Subcommittee et al (2016) Executive summary: heart disease and stroke statistics—2016 update: a report from the American Heart Association. *Circulation* 133:447–454.
- [6]. Vachha BA, Schaefer PW. (2015) Imaging Patterns and Management Algorithms in Acute Stroke: An Update for the Emergency Radiologist. *Radiol Clin North Am*. 2015 Jul;53(4):801-26, ix. doi: 10.1016/j.rcl.2015.02.012.
- [7]. 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>.
- [8]. Kloska, S.P., Wintermark, M., Engelhorn, T. et al. (2010) Acute stroke magnetic resonance imaging: current status and future perspective. *Neuroradiology* 52, 189–201. <https://doi.org/10.1007/s00234-009-0637-1>.

- [9]. 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>.
- [10]. Ali, N. H., Abdullah, A. R., Saad, N. M., Muda, A. S., Sutikno, T., & Jopri, M. H. (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>.
- [11]. Kamal H, Lopez V, Sheth SA (2018). Machine Learning in Acute Ischemic Stroke Neuroimaging. *Front Neurol*. 2018 Nov 8;9:945. doi: 10.3389/fneur.2018.00945. PMID: 30467491; PMCID: PMC6236025.
- [12]. 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.
- [13]. Malik, M., Chong, B., Fernandez, J., Shim, V., Kasabov, NK., Wang, A. (2024). Stroke Lesion Segmentation and Deep Learning: A Comprehensive Review. *Bioengineering*. 2024; 11(1):86. <https://doi.org/10.3390/bioengineering11010086>.
- [14]. 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*.
- [15]. Ehab, W., & Li, Y. (2023, September 22). Performance Analysis of UNet and Variants for Medical Image Segmentation. London.
- [16]. 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.
- [17]. 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>.
- [18]. 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>.
- [19]. 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.
- [20]. 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).
- [21]. Özsunar, Y., Huisman, T., Sorensen, A. G. (2003). Clinical indications of Diffusion Weighted MR Imaging. *Turk J Neurol*. 2003; 9(1): 153-162.
- [22]. Liyuan, C., Zhiyuan, F., Yingjian Yang, Rui Liu, Dajiang Wang, Yingying Feng, Jiahui Lu, Yifeng Fan (2022). "Deep Learning in Ischemic Stroke Imaging Analysis: A Comprehensive Review", *BioMed Research International*, vol. 2022, Article ID 2456550, 15 pages. <https://doi.org/10.1155/2022/2456550>
- [23]. 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>).
- [24]. Taşçı, B. (2023). Automated ischemic acute infarction detection using pre-trained CNN models' deep features. *Biomedical Signal Processing and Control*, 82, 104603. <https://doi.org/10.1016/j.bspc.2023.104603>.

- [25]. Hernandez Petzsche, M. R., de la Rosa, E., Hanning, U., Wiest, R., Valenzuela, W., Reyes, M., ... & Kirschke, J. S. (2022). ISLES 2022: A multi-center magnetic resonance imaging stroke lesion segmentation dataset. *Scientific data*, 9(1), 762.
- [26]. LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* 521, 436–444 (2015). <https://doi.org/10.1038/nature14539>.
- [27]. Fukushima, K. (October 1979). "A Neural Circuit Model for Pattern Recognition Mechanism Unaffected by Shift in Position — Neocognitron." *Trans. IECE (in Japanese)*. J62-A (10): 658–665.
- [28]. LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. [DOI: 10.1109/5.726791].
- [29]. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. [DOI: 10.1145/3065386].
- [30]. Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- [31]. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). Going deeper with convolutions. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 1-9). Boston, MA, USA: IEEE. [DOI: 10.1109/CVPR.2015.7298594].
- [32]. 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).
- [33]. Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 2261-2269). Honolulu, HI, USA: IEEE. [DOI: 10.1109/CVPR.2017.243].
- [34]. Isensee, F., Schell, M., Pflueger, I., Brugnara, G., Bonekamp, D., Neuberger, U., Wick, A., Schlemmer, P., Heiland, S., Wick, W., Bendszus, M., Maier-Hein, K. H., & Kickingereder, P. (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>.
- [35]. Koonce, B. (2021). ResNet 50. In: *Convolutional Neural Networks with Swift for Tensorflow*. Apress, Berkeley, CA. DOI: 10.1007/978-1-4842-6168-2_6.
- [36]. Roeder, L. (2023). NETRON. GitHub. <https://github.com/lutzroeder/netron>