



**DERİN ÖĞRENME YÖNTEMİ İLE BEYİN GÖRÜNTÜLERİNDE
OTOMATİK İNME TESPİTİ**

Büşra UYGUN

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Büşra UYGUN

10/07/2023

DERİN ÖĞRENME YÖNTEMİ İLE BEYİN GÖRÜNTÜLERİNDE OTOMATİK İNME TESPİTİ

(Yüksek Lisans Tezi)

Büşra UYGUN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2023

ÖZET

İnme, beynin bir bölgesine kan akışının kesilmesi veya beynin bir bölgesinde kanamanın olmasıyla meydana gelir. Hızlı müdahale, beyin hasarının azaltılmasına ve iyileşme şansının artmasına yardımcı olmaktadır. Bu yüzden erken teşhis hastalar için büyük önem taşır. İnme tanısı için klinik değerlendirme önemlidir ancak radyolojik görüntüleme yöntemleri teşhis ve tedavi planlamasında daha önemli bir rol oynar. BT (bilgisayarlı tomografi) taraması, inme tanısında ve hastaların durumunun değerlendirilmesinde sıkça kullanılan bir görüntüleme yöntemidir. BT taraması, beyin dokusundaki kanama bölgelerinin konumunu, büyüklüğünü ve yayılımını belirlemek için değerli bilgiler sağlar. Bu bilgiler ise inmenin ciddiyetinin belirlenmesi ve tedavi planlamasının yapılmasında önemli bir rol oynanır. Yapılan çalışmada Türkiye’de düzenlenen Teknofest yarışması aracılığı ile elde edilen BT görüntüleri kullanılarak inme tespiti, sınıflandırması ve bölütleme için iki farklı senaryo uygulanmıştır. Sınıflandırmada ConvNeXt_Tiny, ResNet50d, EfficientNet_b0 ve ResNeXt101_32x8d modelleri kullanılarak ConvNeXt_Tiny’nin daha iyi sonuç verdiği görülmüş ve sınıflandırma işlemlerinde bu model kullanılmıştır. Bölütleme tespitinde de medikal görüntüler üzerinde başarılı olan MultiResUNet modeli kullanılmıştır. Çalışmada iki farklı senaryo izlenmiştir. Birinci senaryoda BT görüntüleri üzerinde kafatası çıkarma, normalizasyon ve görüntü çoğaltma ön işlemlerinin ardından inme var yok sınıflandırması yapılarak test görüntülerinde %98 başarı elde edilmiştir. İnme bulunan görüntüler üzerinde bölütleme yapılarak test görüntülerinde iskemik inme için %59, hemorajik inme için ise %67 Dice bölütleme başarıları elde edilmiştir. Bölütleme sonrası iskemik ve hemorajik inme sınıflandırmasında %100 başarıya ulaşılmıştır. İkinci senaryoda BT görüntülerde ön işlemler yapılarak inme var-yok, iskemik inme ve hemorajik inme şeklinde üç sınıflı sınıflandırmada test görüntüleri üzerinde %97 başarı elde edilmiştir. Sınıflandırma sonucu inmenin bölütleme için oluşturulan modelde Dice bölütleme başarıları iskemik inme için %78, hemorajik inme için ise %79 olmuştur. Çalışmalarda Python programlama dili ve sınıflandırmada PyTorch kütüphanesi, bölütlemede Tensorflow kütüphanesi ile NVIDIA GeForce RTX 3090 ekran kartı kullanılmıştır.

Bilim Kodu : 93008

Anahtar Kelimeler : Beyinde inme, Derin öğrenme, BT, MultiResUNet, ConvNeXt_Tiny

Sayfa Adedi : 73

Danışman : Doç. Dr. Ayşe DEMİRHAN

AUTOMATIC STROKE DETECTION IN BRAIN IMAGES WITH DEEP LEARNING METHOD

(M. Sc. Thesis)

Büşra UYGUN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2023

ABSTRACT

A stroke occurs when blood flow to an area of the brain is cut off or bleeding occurs in an area of the brain. Prompt intervention helps reduce brain damage and increase the chance of recovery. Therefore, early diagnosis is of great importance for patients. Clinical evaluation is important for the diagnosis of stroke, but radiological imaging methods play a more important role in diagnosis and treatment planning. CT (computed tomography) scanning is a frequently used imaging modality in the diagnosis of stroke and in the evaluation of patients' condition. A CT scan provides valuable information for determining the location, size, and spread of bleeding sites in brain tissue. This information plays an important role in determining the severity of stroke and planning treatment. In the study, two different scenarios were applied for stroke detection, classification and segmentation using CT images obtained through the Teknofest competition held in Turkey. It was seen that ConvNeXt_Tiny gave better results by using ConvNeXt_Tiny, ResNet50d, EfficientNet_b0 and ResNeXt101_32x8d models in classification and this model was used in classification processes. MultiResUNet model, which was successful on medical images, was used for segmentation detection. Two different scenarios were followed in the study. In the first scenario, after skull extraction, normalization and image replication pre-processes on CT images, a classification of stroke or not was performed, and 98% success was achieved in the test images. Segmentation was performed on images with stroke, and Dice segmentation success was achieved in test images of 59% for ischemic stroke and 67% for hemorrhagic stroke. After segmentation, 100% success was achieved in ischemic and hemorrhagic stroke classification. In the second scenario, preprocessing was performed on CT images, and a success rate of 97% was achieved on the test images in the three-class classification as stroke present or absent, ischemic stroke and hemorrhagic stroke. In the model created for segmentation of stroke as a result of classification, the success of Dice segmentation was 78% for ischemic stroke and 79% for hemorrhagic stroke. Python programming language and PyTorch library for classification, Tensorflow library for segmentation and NVIDIA GeForce RTX 3090 graphics card were used in the studies.

Science Code : 93008

Key Words : Brain stroke, Deep learning, CT, MultiResUNet, ConvNeXt_Tiny

Page Number : 73

Supervisor : Assoc. Prof. Dr. Ayşe DEMİRHAN

TEŞEKKÜR

Bu tez çalışmasında, ilgi ve yardımlarını esirgemeyen başta değerli danışmanım Doç. Dr. Ayşe DEMİRHAN'a, beni her zaman sakinleştirip çalışma konum üzerinde farklı bakış açıları sunan Ersin KILIÇ ve Çağlar GÜRKAN'a ve akademik ve profesyonel yolculuğumu destekleyen değerli aileme teşekkür ederim. Ayrıca bu süreçte beni hiç yalnız bırakmayan ve her zaman manevi olarak yanımda olan eşim Halil UYGUN'a çok teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR ARAŞTIRMASI	5
3. METOT VE GENEL KAVRAMLAR.....	9
3.1. BT Görüntüleme Tekniği	9
3.2. Veri Seti	12
3.3. Görüntü Ön İşleme	16
3.4. Görüntü Çoğaltma	23
3.5. ConvNext	25
3.6. MultiResUNet	26
3.6.1. MultiResUNet mimarisi	27
3.6.2. Giriş katmanı	29
3.6.3. Konvolüsyon katmanı	29
3.6.4. Batch normalizasyon.....	31
3.6.5. Düzleştirilmiş doğrusal birim katmanı (Rectified linear units layer(ReLu))	32
3.6.6. Maksimum havuzlama katmanı (Max pooling layer)	33
3.6.7. Birleştirme (Concatenate)	35
3.6.8. Tam bağlantılı katman (Fully connected layer)	36
3.6.9. Kayıp fonksiyonları.....	37
3.6.10. Optimizasyon algoritmaları.....	38
3.6.11. Epok, küme boyutu ve öğrenme oranı	39
3.7. Model Performansının Değerlendirilmesi.....	39
4. DENEYSEL ÇALIŞMA VE BULGULAR.....	45

	Sayfa
4.1. Senaryo 1.....	45
4.2. Senaryo 2.....	54
5. SONUÇ VE ÖNERİLER	65
KAYNAKLAR	67
ÖZGEÇMİŞ	73

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Sınıflandırıcı modellerinin inme var ve inme yok sınıflandırma sonuçları	47
Çizelge 4.2. Sınıflandırıcı modellerin ortalama sınıflandırma süresi	47
Çizelge 4.3. İskemik ve hemorajik inmenin bölütleme test sonuçları	48
Çizelge 4.4. Bölütleme sonrası inme türü sınıflandırma test sonuçları	54
Çizelge 4.5. İnme yok, iskemik ve hemorajik inme sınıflandırma başarı sonuçları	56
Çizelge 4.6. İskemik ve hemorajik modellerin bölütleme başarı sonucu	56
Çizelge 4.7. İnme var ve inme yok sınıflandırması	63
Çizelge 4.8. İnme bölütleme başarısı	63

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Bilgisayarlı Tomografi.....	9
Şekil 3.2. Bilgisayarlı Tomografi.....	10
Şekil 3.3. 2D ve 3D BT örnek görüntü	11
Şekil 3.4. Soldan sağa doğru görüntüler: iskemik inme bulunan orijinal BT görüntüsü, orijinal görüntü ile maske görüntüsünün üst üste bindirildiği görüntü ve iskemik inme bölgesini gösteren maske görüntüsü	14
Şekil 3.5. Soldan sağa doğru görüntüler: hemorajik inme bulunan orijinal BT görüntüsü, orijinal görüntü ile maske görüntüsünün üst üste bindirildiği görüntü ve hemorajik inme bölgesini gösteren maske görüntüsü	15
Şekil 3.6. İnme bulunmayan görüntüler.....	16
Şekil 3.7. Soldaki görüntü hiçbir oynama yapılmadan BT görüntü üzerinden alınan beyin görüntüsü, sağdaki görüntü HU +1000 ve üstü değerleri çıkartılmış görüntü.....	17
Şekil 3.8. Soldaki görüntü HU +1000 ve üstü değerleri çıkartılmış görüntü, sağdaki görüntü erozyon ve genişleme sonrası elde edilen görüntü	19
Şekil 3.9. Sağdaki görüntü gerekli alanın belirlenmesi, soldaki görüntü alınması gereken alanın maskı	19
Şekil 3.10. Soldaki görüntü orijinal görüntü, sağdaki görüntü kafatası çıkartılmış görüntü	20
Şekil 3.11. Soldaki görüntü orijinal görüntü, sağdaki görüntü normalizasyon uygulanmış görüntü.....	21
Şekil 3.12. Soldaki görüntü normalizasyon uygulanmış görüntü, sağdaki görüntü normalizasyon üstüne CLAHE uygulanmış görüntü	23
Şekil 3.13. BT kesit görüntüsünün +10, +5 ve -5, -10 derece döndürülmüş halleri.....	24
Şekil 3.14. (A) ConvNeXt-Tiny genel ağ yapısı; (B) ConvNeXt blok yapısı	26
Şekil 3.15. MultiResUNet mimari yapısı.....	26
Şekil 3.16. a) UNet mimarisinde kullanılan konvolüsyonel blok yapısı b) MultiResUNet mimarisinde kullanılan MultiRes blok yapısı	28
Şekil 3.17. Res yolu diyagramı	29
Şekil 3.18. Konvolüsyon çalışma şekli	30
Şekil 3.19. ReLU grafiği.....	33

Şekil	Sayfa
Şekil 3.20. ReLU örnek görüntü	33
Şekil 3.21. Max pooling çalışma şekli	35
Şekil 3.22. Karışıklık matrisi	40
Şekil 4.1. Sınıflandırma modellerinin a) eğitim başarı ve b) kayıp grafikleri	46
Şekil 4.2. Sınıflandırıcı Modellerin Karışıklık Matrisleri.....	47
Şekil 4.3. Soldaki görüntü validasyon görüntüsü, ortadaki görüntü maske görüntüsü, sağdaki görüntü model çıktısı.....	50
Şekil 4.4. İskemik test görüntülerinde kesin doğru ve modelin verdiği sonuç.	51
Şekil 4.5. Hemorajik test görüntülerinde kesin doğru ve modelin verdiği sonuç.....	52
Şekil 4.6. Bölütleme sonrası görüntülerde inme türünü iskemik ve hemorajik olarak belirleyen sınıflandırma işlemine ait eğitim grafikleri	53
Şekil 4.7. İskemik ve hemorajik inme sınıflandırma test görüntülerin karışıklık matrisi	54
Şekil 4.8. İnme yok, iskemik ve hemorajik inme sınıflandırması eğitim grafikleri	55
Şekil 4.9. İnme yok, iskemik inme ve hemorajik inme karışıklık matrisi	55
Şekil 4.10. İskemik modelin validasyon görüntüleri üzerindeki sonucu	57
Şekil 4.11. İskemik modelin iskemik test görüntüleri üzerindeki çıktıları	59
Şekil 4.12. Hemorajik modelin validasyon görüntüleri üzerindeki sonucu.....	60
Şekil 4.13. Hemorajik test görüntülerin hemorajik model üzerindeki çıktıları	62

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

sn

saniye

Kısaltmalar

Açıklamalar

BT

Bilgisayarlı tomografi

CLAHE

Contrast limited adaptive histogram equalization -
Görüntülerin kontrastının algısal tabanlı geliştirilmesi

CNN

Convolution neural network

DICOM

Digital imaging and communications in medicine -
Tıpta dijital görüntüleme ve iletişim

DSA

Dijital subtraksiyon anjiyografi

DSÖ

Dünya Sağlık Örgütü

ESA

Evrişimli sinir ağı

HU

Hausefield unit

ISLES

Ischemic stroke lesion segmentetion

MLP

Multi Layer Perceptron

PET

Pozitron emisyon tomografisi

ReLU

Rectified linear units layer

SVM

Support vector machine

1. GİRİŞ

Beyinde inme, beyin dokusunun hasar görmesi sonucu ortaya çıkan ciddi bir sağlık sorunudur. Beyin dokusu, sürekli bir kan akışına ihtiyaç duyar. Beyinde kan akışının azalması, kesilmesi beyin dokusunun hasar görmesine ve hücrelerin ölmesine veya az da olsa beyin damarlarından herhangi birinin yırtılıp, yırtılma sonucu oluşan kanın beyin dokusuna veya beyin zarlarına ulaşması ile inme oluşur. Beyinde inme, ciddi bir sağlık sorunu olmasının yanı sıra, ölümcül sonuçlar doğurabilir. Beyin hasarının derecesine, inmenin yerine ve büyüklüğüne bağlı olarak, inme sonrası felç, konuşma bozukluğu, bilişsel bozukluklar, hafıza kaybı gibi birçok uzun vadeli etkiler oluşabilir [1].

Dünya Sağlık Örgütü inmeyi damarsal neden dışında görünürde bir sebep olmaksızın, aniden yerleşip beyinde yerel veya genel fonksiyon bozukluğuna yol açan, ölümle sonuçlanan veya kalıcı hasar bırakan bir hastalık olarak tanımlamıştır. İnme sakatlık sebepleri içerisinde birinci ve ölüm yönünden de üçüncü sırada yer almaktadır [2].

Beyinde iki adet inme sınıfı bulunmaktadır. Bunlar iskemik (tıkamalı) ve hemorajik (kanamalı) inmedir. İskemik (tıkamalı) inme, beyindeki bir bölgedeki kan akışının kesilmesi veya azalması sonucu oluşan bir tür inmedir. İskemik inme, genellikle bir arterdeki tıkanıklık, emboli veya daralma nedeniyle meydana gelir ve kan, oksijen ve besinlerin beyine ulaşmasını engeller. Damar tıkanıklığı ile meydana gelen inme, fokal serebral, spinal veya retinal enfarkta bölgelerdeki dokuların ölümüne neden olur [3]. İskemik inme, inme türlerinin %80'ini oluşturmaktadır [1]. İskemik inme birçok semptomla neden olabildiği gibi yaygın semptomları yüzün bir kısmında veya kol ve bacaklarda his azlığı veya güçsüzlük, konuşma bozukluğu, görme bozukluğu, baş ağrısı, baş dönmesi veya denge kaybı bulunur. Semptomlar, hasar gören bölgeye ve inme alanının ne kadar büyük olduğuna bağlı olarak değişebilir.

Hemorajik (kanamalı) inme, beyinde kanama sonucu oluşan bir tür inmedir. Bu tür inmelerin en yaygın nedeni, beyin arterlerinde bir anevrizmanın patlaması veya kan damarlarının zayıf noktalarında bir kanama olmasıdır [4]. Hemorajik inme, acil tıbbi müdahale gerektiren ciddi bir durumdur. Tedavi, kanamanın kaynağını belirlemeyi, kanamanın durdurulmasını sağlamayı ve beyin hasarını azaltmayı içerir.

Dünya Sağlık Örgütü (DSÖ) verilerine göre, beyin ve dolaşım sistemi hastalıkları dünya genelinde ölümlerin en yaygın nedenidir ve bunların büyük bir kısmı inme kaynaklıdır. DSÖ'ye göre, her yıl dünya genelinde yaklaşık 15 milyon insan beyin damarlarının tıkanması veya beyin kanamaları nedeniyle inme geçirmekte ve yaklaşık 5 milyon insan ise bu nedenle hayatını kaybetmektedir [5]. DSÖ'nün verilerine göre inme, gelişmiş ülkelerde kardiyovasküler hastalıklar ve kanserden sonra en sık üçüncü ölüm nedenidir [6-7].

Hemorajik ve iskemik inme türlerinde klinik tanı yanında radyolojik görüntü üzerinde de tanı çok önemlidir. Genellikle beynin bilgisayarlı tomografisi (BT) klinik açıdan inme tanısı düşünülen hastalarda ilk seçenek olarak uygulanan radyolojik görüntüleme yöntemidir [8]. BT taraması, inme hastalarında hızlı ve etkili bir şekilde beyin hasarının tespit edilmesine yardımcı olur.

Doktorların medikal görüntülerin gözle bakarak sınıflandırması, değerlendirmesi ve analiz etmesi hem zaman hem de maliyet yönünden olumsuz etkilemektedir. Hassas veri olarak da bilinen medikal görüntüler, analiz edilen kişiler tarafından yanlış bir yorum ya da değerlendirme yapılması hasta açısından hayati önem taşımaktadır [9]. Tedavinin hızlı bir şekilde başlatılması ve beyin hasarının azaltılması için bu radyolojik görüntüler büyük önem taşımaktadır. İnmenin ne kadar şiddetli olduğunu belirlemek, hangi tedavi seçeneklerinin uygulanabileceğine karar vermek ve tedavi sürecinin izlenmesi için BT taraması kullanılmaktadır. Bu şekilde erken müdahale ile hastanın iyileşme sürecini hızlandırıp hastalığı az hasarla atlattırması sağlanır. Radyolojik görüntüler ile yapılan çalışmaların doktorlara ikinci bir göz imkanı sunarak teşhise karar verme konusunda destek sağlanır.

İnsan için görüntüler, görsel algılarla tanımlanan ve gözler aracılığıyla beyine iletilen bilgilerdir. İnsan gözü görüntüleri bütünsel olarak algılar. Görüntüleri değerlendirerek bilgi çıkarmak, insan gözü için doğal ve içgüdüsel bir görevdir. Bilgisayar için görüntüler, sayılarla temsil edilen bir matris şeklinde ifade edilir. Görüntü bölütlemesi, bilgisayarla görme ve uydu görüntüleri gibi alanlarda aktif ve büyük bir araştırma alanı olarak öne çıkmaktadır. Bilgisayarın amacı, belirli bir kişi için görüntüyü anlamlı bir şekilde işlemek ve sunmaktır. Görüntüyü anlamlı hale getirmek için çeşitli yöntemler ve yaklaşımlar kullanılır. Hangi yöntemin seçileceği, çözülecek problem veya problemin özelliklerine

bağlıdır. Görüntü bölütlemesi, bir görüntüdeki nesnelerin veya bileşenlerin tanımlanması ve sınıflandırılması sürecinde kritik bir aşamadır. Bu aşama, görüntüdeki farklı öğeleri ayırarak ve gruplandırarak her birine ait bilgiyi elde etmeyi amaçlar. Bu sayede, görüntüdeki farklı öğelerin özellikleri daha iyi anlaşılabilir, ayrıştırılabilir ve analiz edilebilir. Görüntü bölütlemesi, görüntü işleme, bilgisayarlı görü ve yapay zeka gibi alanlarda geniş bir öneme sahiptir [10].

Biyomedikal görüntülerin bölütleme için bir dizi yöntem önerilmiştir. Fakat bu yöntemlerden hangisinin en iyi olduğunu söylemek imkansızdır [9]. Çünkü biyomedikal görüntülerdeki bölütleme dokunun tipine bağlı olarak değişmektedir. Bunun yanında görüntülerin bileşenlerine, benzerliği olan doku, yerel renk ve diğer farklı özelliklerine göre bölütleme işlemi değişmektedir [11]. Tıbbi görüntülerin bileşenlerine ayrılması ve anatomik alt yapıların işaretlenmesi bölütleme tekniği kullanılarak gerçekleştirilebilir. Bu teknik, cerrahi ve anatomik inceleme gibi tıbbi uygulamalarda görüntü işlemeyle ilişkilidir. Bölütleme, görüntü üzerindeki yoğunluk, doku, gradyan ve diğer ölçülebilir özelliklerin birleşimine dayanan nesnel ve öznel metotlar kullanılarak gerçekleştirilir. Bölütleme tekniği, görüntü üzerindeki belirli yapıları veya bölgeleri tanımlamayı ve ayırt etmeyi sağlar. Bu işlem genellikle özellik çıkarma ve istatistiksel örüntü modellemesi gibi yöntemlerle gerçekleştirilir. Yoğunluk, doku, gradyan gibi özellikler, bölütleme işlemi için kullanılan özellikler arasında yer alabilir. Bölütleme, medikal görüntülerdeki anatomik yapıların belirlenmesinde büyük önem taşır. Bu teknik, hastalıkların tanısında, cerrahi planlamada, tedavi takibinde ve patoloji analizinde kullanılabilir. Örneğin, bir BT görüntüsünde inme türünü belirleyerek cerrahi müdahaleyi kolaylaştırabilir veya bir röntgen görüntüsünde kemikleri ayrıştırarak kırıkları tespit edebilir. bölütleme tekniği, medikal görüntülerin analizini ve yorumlanmasını hızlandırarak tıbbi teşhis ve tedavi süreçlerinin de hızlı bir şekilde uygulanmasında önemli bir rol oynar [12].

Bölütleme işlemi bölge tabanlı veya piksel (voksel) tabanlı olarak uygulanabilir. Bölge tabanlı bölütleme teknikleri, bağıntılı bölgeleri tanımlamak için kullanılır. Bu yöntemde, bir bölgenin karakteristik şekil, doku veya belirgin sınırlar gibi ortak özelliklere sahip olması beklenir. Örneğin, bir bölgenin yoğunluğu, renk dağılımı veya dokusal özellikleri, o bölgenin diğer benzer bölgelerden ayrılmasında kullanılabilir. Piksel tabanlı bölütleme tekniklerinde ise her piksel ayrı ayrı ele alınır ve nesnelerle ilişkilendirilir. Bu yöntemde, grup içi ve gruplar arası farklılıkları incelemek için istatistiksel araçlar ve ön işleme

yöntemleri kullanılır. Piksellerin yoğunluk değerleri, renk, gradyan veya diğer özellikler üzerinden analiz edilerek bölütleme gerçekleştirilebilir. Görüntü bölütleme, görüntüden çıkarılan özelliklere dayanır. Görüntünün yoğunluk değeri, bölütlemenin en belirleyici özelliklerinden biridir. Bunun yanı sıra, görüntünün diğer özellik çıkarımları da yoğunluk değeri temel alınarak elde edilebilir. Örneğin, kenarlar, dokusal desenler veya morfolojik özellikler gibi özellikler, bölütleme sürecinde kullanılabilir. Bölütleme yöntemleri, görüntü analizinde önemli bir rol oynar ve farklı uygulama alanlarında kullanılır. Bu yöntemlerin seçimi, hedeflenen uygulama ve görüntü özelliklerine bağlı olarak yapılır [13].

Bu tez çalışmasında, BT görüntüler kullanılarak evrişimli sinir ağları (CNN) temelli derin öğrenme yöntemleriyle görüntü üzerinde inme olup olmadığı, inme varsa hangi inme türünün olduğu ve inmenin bulunduğu bölge tespit edilerek doktorlara ikinci bir göz olarak sunulacak bir yöntem geliştirilmiştir.

Bu çalışma DICOM formatında yüksek çözünürlüklü ve kaliteli veriler ile gerçekleştirilmiştir. 7683 veriyle yapılan sınıflama ve bölütleme sonucunda yüksek bir doğruluk oranına ulaşılmıştır. Bu çalışmadan elde edilen sonuçlar literatürdeki çalışmalarla karşılaştırıldığında kullanılan yöntemin daha başarılı sonuçlar verdiği tespit edilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Beyinde inme tespiti ile ilgili literatürde farklı modeller ve farklı veriler üzerinde gerçekleştirilmiş birçok çalışma bulunmaktadır. Bu çalışmalarda BT görüntülerin yanı sıra farklı radyolojik görüntüler de kullanılmaktadır.

İnme sınıflandırma çalışmalarında Yongzhao Xu ve arkadaşları [14] hemorajik inme tespiti yapmıştır. Her birinde hemorajik inme bulunan 356 adet DICOM formatındaki BT görüntülerini kullanarak iki farklı yol izlemişlerdir. Birinci yolda görüntülere ön işlem uygulayarak farklı sınıflandırma modellerini kullanmışlardır. İkinci yolda ise Mask-RCNN ile inmenin yerini tespit etmiş ve sadece bu bölgenin görüntüsünü kullanarak sınıflandırma işlemi gerçekleştirmişlerdir. Birinci yol ile elde edilen %97 doğruluk (accuracy) yönteminde ResNet50 ile birlikte MLP (Multilayer perceptron) modeli kullanılmıştır. İkinci yolda ise Mask-RCNN ile yer tespit ederek matematik morfoloji yöntemlerinden genişleme (dilation) ve erozyon (erosion) yöntemlerini kullanarak sadece inme alanlarını belirlenmiş ve makine öğrenmesi ile bölgelerin özelliklerini çıkartarak inme olup olmadığını tespit etmişlerdir. Bu özellikler ile sınıflandırma başarılarını %99 a çıkartmışlardır [14]. Valeriia Abramova ve arkadaşları [15] hemorajik inme bölütleme çalışmalarını 3D SE U-Net (squeeze-and-excitation blocks U-NET) modelini kullanarak yapmışlardır. Çalışmalarında İspanya, Girona'daki Dr. Josep Trueta Hastanesinde alınan 76 kontrastsız BT görüntüsünü kullanmışlardır. Görüntü çoğaltma işlemi olarak görüntüleri yamalara (patch) ayırarak döndürme, aynalama gibi ön işlemler yapmışlardır. SE 3D-Unet modellerinde 3x3x3 konvülasyon ve 2x2x2 max pooling kullanmışlardır. $32 \times 32 \times 16$ boyutunda 3000 adet yama çıkartılıp sadece inme bulunan bölgeleri eğitimde kullanmışlardır. Yapılan çalışma sonucunda 3D U-Net ile elde edilen başarı %76 iken SE U-Net yöntemi ile %82 Dice başarısi elde etmişlerdir [15]. U. Raghavendra1 ve arkadaşları [16] 2021 yılında makine öğrenmesi yöntemi ile hemorajik inme ve inme değil şeklinde sınıflandırma çalışmaları yapmışlardır. Bu çalışmada BT görüntüleri, Kalinga Tıp Bilimleri Enstitüsü'nün (KIMS), Bhubaneswar, Hindistan Radyo-Tanı Departmanından 48 hastadan 784 normal ve 819 hemorajik inme bulunan görüntü kullanmışlardır. Öncelikle CLAHE histogram yöntemi ile görüntü iyileştirme yapmışlar, daha sonra beyindeki eşik değerler (threshold) kullanılarak beyindeki gerekli olan alanları çıkartmışlardır. Beyin dokusundaki morfolojik değişiklikler ve önemli doğrusal olmayan doku tabanlı özellikleri kullanarak

farklı entropi yöntemler ile özellikler çıkartılmıştır. Bu özellikler eğitim ve test görüntü arasındaki istatistiksel farkı ölçmektedir. Bu yöntem, iki sınıf ortalamasının farkı ile iki sınıfın değişkenliği arasındaki oranın hesaplanmasına yardımcı olur. Daha sonra K-NN, PNN ve SVM sınıflandırma metotları ile %97 doğruluk elde edilmiştir [16].

Anjali Gautam ve arkadaşları [17] hemorajik ve iskemik inme sınıflandırma yöntemi üzerinde çalışma yapmışlardır ve kendi geliştirdikleri yönteme P_CNN adı vermişlerdir. 18 hemorajik inme vakası, 25 iskemik inme vakası ve 31 normal vaka bulunan hastaların DICOM görüntüleri ile iki farklı veri seti oluşturarak sınıflama yapmışlardır. Birinci veri setinde sadece hemorajik ve iskemik veriler üzerinde 10 kat çapraz doğrulama ile Alexnet kullanarak %95 sınıflama doğruluğu elde ederken önerdikleri yöntem ile %98 başarı elde etmişlerdir. İkinci veri setinde iskemik, hemorajik ve inme olmayan görüntüler üzerinde Alexnet kullanarak %88, önerdikleri model ile %93 sınıflama başarıları elde etmişlerdir [17].

Tessy Badriyah ve arkadaşları [18] iskemik ve hemorajik sınıflandırma için Endonezya, Surabaya'daki Hajj Hastanesinden elde edilen verileri kullanmıştır. 99 hastanın verisi iskemik ve 3 hastanın verisi de hemorajiktir olmak üzere 102 hastanın verisini kullanmışlardır. Gray-Level Co-Occurrence Matrix (GLCM) yöntemi ile görüntülerden özellikler çıkartılarak sınıflandırma için 8 farklı (K-Nearest Neighbors, Naive Bayes, Logistic Regression, Decision Tree, Random Forest, Multi-layer Perceptron (MLP-NN), Deep Learning and Support Vector Machine) yöntem kullanmışlardır. Yapılan çalışma sonucunda Random Forest metodunun %95 başarılı olduğu görülmüştür [18].

A.S. Neethi ve arkadaşları [19] Hindistan'daki Sree Chitra Tirunal Tıp Bilimleri ve Teknoloji Enstitüsü'nden (SCTIMST) 70 hasta iskemik, 68 hasta hemorajik ve 96 normal kişiye ait kontrast içermeyen BT görüntüleri kullanarak 3D yöntemi ile inme olup olmadığı konusunda çalışmalar yapmışlardır. 3D-ResNet-101 ile %90 başarı elde ederken çalışmada önerdikleri yöntem ile %92 başarı elde etmişlerdir [19].

Mohsen Soltanpour ve arkadaşları [20] ISLES 2018 BT görüntülerinden eğitim için 63 hastanın 94 görüntüsünü ve test için de 40 hastanın 62 görüntüsünü kullanmışlardır. Her görüntüde 2 ile 22 arasında dilim bulunmaktadır. Öncelikle görüntü çoğaltma ve iyileştirme çalışmaları yapmışlardır. İyileştirme çalışmaları olarak normalizasyon yöntemi

uygulanırken görüntü çoğaltmada döndürme işleminin yanında Gauss gürültüsü eklenmiştir. Bu görüntüler dört adet 2D U-Net'i kullanarak, dört adet CTP haritasından (CBV, CBF, MTT, Tmax) inme lezyonunun konumu hakkında bilgiler ayrı ayrı çıkartarak model oluşturulur. Bu model daha sonra piksellerin lezyon mu yoksa sağlıklı dokular mı olduğuna karar vermek için U-Net tarafından çıkarılan olasılık haritalarını birleştirilir. Bu yaklaşım, değişen şekillerine rağmen inme lezyonunu öğrenmek için her bir pikselin yanı sıra komşuluğu hakkındaki bilgileri kullanılır. Son olarak U-Net çıktıları ile elde edilen her piksel çıktısı bir sınıflandırıcıyla sınıflandırılmıştır. Başarı skorları hem sınıflandırma hem de bölütlemeye %71'dir [20]. Lucas de Vries ve arkadaşları [21] da ISLES 2018 BT görüntüler üzerinde bölütleme işlemini kendi oluşturdukları PerfU-Net modeli kullanarak yapmışlardır. C (kanal) x T (frame sayısı) x H (görüntü yükseklik) x W (görüntü genişlik) olarak görüntüleri önce kanal dikkat bloğuna daha sonra da geçici dikkat bloğa göndererek veya ayrı ayrı max ve mean dikkat blokları kullanarak özellik çıkartımı ve bölütleme işlemi gerçekleştirmişlerdir. Elde edilen sistemde en iyi sonuç kanal dikkat bloğundan elde edilen sonuçtur ve %51 Dice bölütleme başarısı elde etmişlerdir [21].

Yue Ma ve arkadaşları [22] hemorajik inmenin türleri olan intraventriküler (IVH), intraparenkimal (IPH), subaraknoid (SAK), epidural (EDH), subdural (SDH) ve hemorajik inme yok tespiti üzerinde çalışma yapmışlardır. Çalışmada kullanılan Irak'daki Al Hilla Teaching Hastanesinden elde edilen veri setinde 36 tanesinde hemorajik inme bulunan 82 BT görüntüsü kullanılmıştır. U-Net modelini modifiye ederek IHA-Net isimli bir model oluşturmuşlardır. Bu modelin U-Net'ten farkı kod çözücü kısmında RHAC (Residual Hybrid Atrous Convolution) yöntemi uygulayarak bölütleme yapmasıdır. Sınıflandırmada da ResNet34 kullanmışlardır. Bölütleme başarısı olarak %72 Dice, %60 Jaccard bölütleme başarısı bulunmaktadır [22].

Tao Han ve arkadaşları [23] inme ve akciğer bölge tespiti konusunda çalışma yapmışlardır. Yaptıkları çalışmadaki akciğer verilerini Brezilya'daki Walter Cantídio daki The Federal University of Ceará (UFC), inme verilerini de Brezilya'daki The Heart Hospital of Fortaleza hastanelerinden almışlardır. Bütün verilerden Xception CNN modeli ile özellikler çıkartarak SVM ile sınıflandırma yapmışlardır. Sınıflandırmada inme kontrolü sağlanmaktadır. Daha sonra da inme varsa Detectrone2 CNN modeli kullanarak bölütleme işlemi yapılmıştır. %94 Dice bölütleme başarısı elde edilmiştir [23].


Teknofest yarışmasında birinci olan AI-DEO [24] takımı yaptığı çalışmada bu çalışmada kullanılan verileri kullanmıştır. Veri iyileştirme ve çoğaltma işlemleri olarak CenterCrop, Flip, ShiftScaleRotate ve OneOf yöntemlerini kullanmışlardır. ResNeXt-50 (32×4d) modelini kullanarak inme var ve inme yok sınıflandırma işleminde test görüntüleri üzerinden %88 başarı elde etmişlerdir. Daha sonra inme olan görüntüleri bölütleme modeli olarak Unet ve sınıflandırma modeli olarak EfficienNet kullanarak %65 bölütleme ve %65 sınıflandırma başarı elde etmişlerdir [24]. Teknofest yarışmasında ikinci olan GÖKSENİN-AI [25] takımı yaptığı çalışmada Teknofest verilerine ek olarak açık erişim veri kümelerini de [26] kullanmıştır. İnme var yok sınıflandırma çalışmasında DesneNet201 modelini kullanarak %98.78 başarı elde etmişlerdir. Bölütleme ve inme türü sınıflandırma çalışmasında Unet+InceptionResNetV2 modeli kullanarak hemorajik inme için %63 bölütleme doğruluk elde ederken iskemik inme için %76 başarı elde etmişlerdir [25]. Teknofest yarışmasında Aprİkod [27] adı olan takımın yaptığı çalışmada teknofest verilerine ek olarak ISLES verilerin bazılarını da kullanmıştır. İnme var ve yok sınıflandırmada VGG-16 kullanarak test görüntülerden %94 başarı elde etmişlerdir. Bölütleme olarak da U-Net modeli kullanarak eğitim sonucu hemorajik ve iskemik inmede %60 başarı elde etmişlerdir [27]. Teknofest yarışmasındaki bir diğer takım adı AI Knight [28] olan takımın yaptığı çalışmada inme var ve yok için kullandıkları DenseNet modelinin test sonucu %94'tür. Bölütleme olarak U-Net modelini kullanarak eğitim sonucu hemorajik ve iskemik inmede %54 başarı elde etmişlerdir [28]. Teknofest bir diğer brAInstorm [29] adını kullanan takım inme var ve yok sınıflandırmasında ve bölütlemeye de U-Net modelini kullanmıştır. İnme var ve yok sınıflandırmada test görüntülerinden elde ettiği başarı %87 iken bölütleme için kullandığı test görüntülerinden hem iskemik hem de hemorajik inmede %50 başarı elde etmiştir [29].

3. METOT VE GENEL KAVRAMLAR

Metot ve genel kavramlar bölümünde, BT görüntüleme tekniği, kullanılan veri seti, görüntü ön işleme, MultiResUNet ve MultiResUNet modelinde kullanılan yöntemler, parametreler ve metotlar hakkında bilgi verilecektir.

3.1. BT Görüntüleme Tekniği

Bilgisayarlı Tomografi (BT), dar bir X-ışını demetinin bir hastaya yönlendirildiği ve hızla vücudun etrafında döndürüldüğü bir bilgisayarlı X-ışını görüntüleme prosedürünü ifade eder. Bu prosedürde, X-ışınlarından elde edilen sinyaller makinenin bilgisayarı tarafından işlenir ve kesitsel görüntüler veya "kesitler" oluşturulur. Bu kesitler, geleneksel röntgenlere göre daha ayrıntılı bilgiler sağlayabilir. Makinenin bilgisayarı tarafından toplanan bir dizi ardışık kesit, dijital olarak bir araya getirilerek hastanın üç boyutlu bir görüntüsü oluşturulabilir. Bu görüntü, temel yapıların daha kolay tanımlanmasına ve olası inmenin veya anormalliklerin tespit edilmesine olanak sağlar [30].



Şekil 3.1. Bilgisayarlı Tomografi [31]

Şekil 3.1’de BT’nin ana elemanlarının fonksiyonları gösterilmiştir.

Bunlar [31];

Dönen X-ışını tüpü:


- Hastanın etrafında döner
- Tüpteki yüksek enerjili elektrotlar radyasyon demetlerini yayınlar.
- Radyasyon, hastanın vücudundan geçer

Radyasyon dedektörleri:


- X-ışını tüpünün karşısında, hastanın vücudunun diğer tarafında bulunur.
- Dokuların içinden geçtikten sonra kalan radyasyonu (değişken yoğunluk şeklinde) emer ve ölçer.
- Bilgisayar yazılımı, dedektör tarafından üretilen tomografik bilgileri algılar ve bir görüntüyü yeniden oluşturur.

Motorlu masa:

- Hastayı tarayıcıda ilerletir.



Şekil 3.2. Bilgisayarlı Tomografi [32]



Şekil 3.3. 2D ve 3D BT örnek görüntü

BT görüntülemeye (Şekil 3.2) motorlu masaya hasta yatırıldıktan sonra çekim için hazır pozisyona getirilir. Daha sonra motorlu masa ile hasta BT görüntüleme sistemi içinde hareket ettirir. X-ışını kaynağı dairesel açıklık içinde dönerken, uzak tarafta bir dizi X-ışını dedektörü de senkronize olarak döner. X-ışını kaynağı, genişlikleri 1 ila 20 mm arasında değişen dar ve yelpaze şeklinde bir ışın üretir. Baş taramaları için yaygın olarak kullanılan aksiyel BT’de masa bir dönüş sırasında sabit durur ve daha sonraki dilim için hareket ettirilir. Vücut taramaları için yaygın olarak kullanılan helikal BT’de ise masa sürekli olarak hareket ederken, X-ışını kaynağı ve dedektörler döner ve spiral veya helikal bir tarama oluşturur. İllüstrasyonda tek bir sıra dedektör gösterilse de, mevcut makineler genellikle yan yana çalışan çok sayıda dedektör sırasına sahiptir, böylece bir seferde birçok dilim (şu anda 128’e kadar) aynı anda görüntülenebilir ve genel tarama süresi azaltılır. Tüm veriler bilgisayar tarafından işlenerek, hedef organın veya vücut bölgesinin üç boyutlu bir görünümünü temsil eden bir dizi görüntü dilimi oluşturulur [32]. Şekil 3.3’de anlamlı hale gelen görüntüleri göstermektedir.

BT tetkiki, hem kontrastlı (iyot bazlı kontrast madde kullanılarak) hem de kontrastsız olarak yapılabilmektedir. Genel kullanım durumları:

Kontrastsız BT:

1. Beyinde akut kanama, travma sonrası yaralanma, inme veya tümör tespiti gibi durumlar
2. Kemik kırıkları, tümörler veya enfeksiyonlar gibi iskelet sistemi sorunlarının değerlendirilmesi
3. Üriner sistemde taş veya diğer anormalliklerin tespiti
4. Akciğerlerde nodüller veya diğer lezyonların belirlenmesi.

Kontrastlı BT:

1. Yumuşak dokuda tümörlerin, enfeksiyonların veya iltihapların daha iyi görüntülenmesi
2. Kan damarlarının (vasküler sistem) değerlendirilmesi, örneğin pulmoner emboli (akciğer damarlarında tıkanma), aort anevrizması veya aort diseksiyonu şüphesi durumu
3. Karın içi organların (karaciğer, böbrek, dalak vb.) ayrıntılı değerlendirilmesi.


BT tetkiki sırasında kontrast kullanılıp kullanılmayacağı, doktorlar tarafından hastalık veya durumun gereksinimlerine göre belirlenir. Karar, semptomların, klinik değerlendirme ve diğer görüntüleme yöntemleriyle birlikte dikkate alınır. Bu çalışma kapsamında kontrastsız BT görüntüleri kullanılmıştır.

3.2. Veri Seti


Türkiye’de organize edilen Teknofest Havacılık, Uzay ve Teknoloji Festivali, Türkiye’nin millî teknoloji adımları atmasında önemli rol oynayan kurum ve kuruluşlarının desteklediği, Türkiye’nin ilk ve tek havacılık, uzay ve teknoloji festivalidir. Türkiye'nin teknoloji alanında yetkinliğini artırması ve etkin bir konuma gelmesi için temel bir paradigmatik değişim gerekmektedir. Bu değişimin en önemli unsurları, toplumun millî teknoloji geliştirme süreçlerine daha fazla destek vermesi ve nitelikli insan kaynağının yetişmesine katkı sağlamasıdır. Bu iki faktör, Türkiye'nin teknoloji alanında söz sahibi olabilmesi için hayati öneme sahiptir. Türkiye'nin teknolojik yetkinliğini geliştirmek ve etkin bir şekilde söz sahibi olmak için, her bireyin ülkemizin kabiliyetlerine, gücüne ve

geleceğine olan inancı aynı ideal ve heyecanla paylaşması gerekmektedir. Bu, "Milli Teknoloji Hamlesi"nin temelini oluşturur. Bu hedefler doğrultusunda, toplumun her bir bireyi ortak bir inançla ve coşkuyla Türkiye'nin teknolojik potansiyeline güvenmeli ve geleceğimize katkıda bulunmalıdır. Bu hedefe ulaşabilmenin ön koşullarından birisi ise dünyada yüksek teknoloji projelerinin lokomotifi kabul edilen havacılık ve uzay alanlarında söz sahibi olabilmektir. Teknofest kapsamında gerçekleştirilen fuar etkinlik alanları, uçuş gösterileri, seminerler ve aktiviteler ile toplumun her kesiminin Milli Teknoloji Hamlesi'ne olan ilgilerinin artırılması hedeflenmiştir. Bu faaliyetler ile birlikte bu sene 41 farklı kategoride düzenlenen teknoloji yarışmalarıyla da ülkemizin yetişmiş nitelikli insan kaynağına katkı sunulması amaçlanmıştır. Bu kapsamda Teknofest yarışmasının bir alt dalı olan Sağlıkta Yapay Zeka yarışması kapsamında beyinde inme yarışması gerçekleşmiş ve bu yarışmada kullanılması için Sağlık Bakanlığı tarafından belirlenen ve etiketlenmiş veriler kullanıcılara verilmiştir [33]. Bu veriler daha sonra herkesin erişebileceği bir şekilde paylaşma açılmıştır [34].


Veri seti, anonim beyin BT kesit görüntülerinden oluşmaktadır, DICOM ve PNG formatlarında sunulmaktadır. Toplamda 6951 beyin BT kesiti içeren veri setinde, 7 radyolog tarafından etiketleme ve bölütleme işlemleri gerçekleştirilmiştir. Bu işlemlerde, bir radyolog tarafından yapılan işaretlemeler, başka bir radyolog tarafından kontrol edilmiştir. Veri setindeki kesitlerin 4557'sinde inme bulguları izlenmezken, 2394'ünde inme bulunmaktadır. Görüntülerde 1130 kesit iskemik inme, 1093 kesit hemorajik inme ve 171 kesit her iki inme tipinden bulgular bulunmaktadır. PNG formatında sunulan veri seti, orijinal görüntüleri, maske görüntülerini ve bunların orijinal görüntü üzerinde yerleştirildiği hallerini içermektedir. Şekil 3.4, Şekil 3.5 ve Şekil 3.6'da veri setinde bulunan örnek görüntüler gösterilmektedir. Bu çalışmada hem DICOM hem de PNG görüntülerinden yararlanılmıştır.



Şekil 3.4. Soldan sağa doğru görüntüler: iskemik inme bulunan orijinal BT görüntüsü, orijinal görüntü ile maske görüntüsünün üst üste bindirildiği görüntü ve iskemik inme bölgesini gösteren maske görüntüsü




Şekil 3.5. Soldan sağa doğru görüntüler: hemorajik inme bulunan orijinal BT görüntüsü, orijinal görüntü ile maske görüntüsünün üst üste bindirildiği görüntü ve hemorajik inme bölgesini gösteren maske görüntüsü



Şekil 3.6. İnme bulunmayan görüntüler

3.3. Görüntü Ön İşleme

Teknofest Sağlıkta Yapay Zeka kategorisinin alt dalı olan Beyinde İnme Tespiti yarışması DICOM verilerini okumak için pydicom [35] kütüphanesi kullanılmıştır. DICOM görüntüler ayrıca rekonstrüksiyon algoritmaları tarafından okunur ve yeniden oluşturulur. Rekonstrüksiyon algoritması, her kesit için lineer atenüasyon katsayılarını hesaplayarak BT numaralarını belirler. BT numaraları, atenüasyon katsayılarıyla ilişkilidir ve her bir numara bir dokuyu temsil eder. Bu numaralar Hounsfield Ünit (HU) olarak adlandırılır ve -1000 ile +1000 arasındaki bir yoğunluk aralığında değerlendirilir. HU numaraları, farklı dokuların yoğunluklarına karşılık gelir. Örneğin, -1000 HU değeri havayı temsil ederken, sıfıra yakın negatif değerler (-10, -20) yağ dokularını, sıfıra yakın pozitif değerler (+10, +30) sıvı yapıları temsil eder. +300, +350 gibi daha yüksek HU değerleri kalsifiye yapıları gösterirken, +1000 en yoğun yapı olan kemik yapısını temsil eder. Bu şekilde, BT numaraları farklı dokuların yoğunluklarını belirlemek için kullanılır [37]. Bu bilgiden yararlanarak +1000 üstündeki değerindekileri görüntü üzerinden pixel array yardımıyla elde edilerek orijinal png görüntü üzerinden çıkartılıp kemik olmayan görüntü elde edilir. Şekil 3.7’de HU değerinden yararlanarak kemiği çıkartılmış beyin görüntüsü gösterilmektedir.



Şekil 3.7. Soldaki görüntü hiçbir oynama yapılmadan BT görüntü üzerinden alınan beyin görüntüsü, sağdaki görüntü HU +1000 ve üstü değerleri çıkartılmış görüntü

Daha sonra 4x4 oluşan bir matris ile erozyon ve genişleme işlemleri yapılarak görüntü üzerinden önce küçük noktalar erozyon yöntemi ile yok edilmiş, sonrasında kenar kayıpların önlenmesi için genişleme işlemi yapılmıştır.

Erozyon (erosion), morfolojik görüntü işleme operasyonlarından biridir. Bir görüntü üzerinde yapılandırma elemanı kullanılarak gerçekleştirilir ve görüntünün sınırlarını aşındırma, küçük nesneleri veya gürültüyü kaldırma amacıyla kullanılır. Erozyon işlemi, bir pikselin çevresindeki diğer pikselleri etkileyerek görüntüdeki nesneleri daraltır veya küçültür.

Erozyon işlemi, aşağıdaki adımlarla gerçekleştirilir:

1. Giriş görüntüsü ve yapılandırma elemanı belirlenir. Yapılandırma elemanı, erozyon işlemi sırasında hangi piksellerin etkileneceğini belirlemek için kullanılır. Yapılandırma elemanı, genellikle kare, dikdörtgen, daire veya çapraz gibi geometrik şekillere sahip olabilir.
2. Giriş görüntüsü üzerinde yapılandırma elemanı hareket ettirilir. Her bir piksel için yapılandırma elemanı ile çakıştırma (overlap) yapılır.
3. Yapılandırma elemanı ile çakışan piksellerin minimum değeri alınır ve bu değer, aşındırılmış görüntünün ilgili pikselinin değeri olarak atanır. Bu işlem çevredeki nesnenin daralmasına veya küçülmesine neden olur.

4. 2. ve 3. adımlar, tüm pikseller üzerinde tekrarlanır, böylece erozyon işlemi tamamlanır.


Erozyon işlemi, görüntüdeki nesneleri daraltırken, nesnelerin sınırlarını düzleştirir, küçük nesneleri küçültür veya tamamen kaldırır ve gürültüyü azaltır. Yapılandırma elemanının boyutu ve şekli, erozyon işleminin sonucunu etkileyen faktörlerdir. Büyük bir yapılandırma elemanı daha fazla daralma sağlarken, küçük bir yapılandırma elemanı daha ince detaylara etki edebilir [38-39].

Genişleme (dilation), morfolojik görüntü işleme operasyonlarından biridir. Bir görüntü üzerinde yapılandırma elemanı kullanılarak gerçekleştirilir ve görüntünün sınırlarını genişletme, delikleri doldurma veya nesneleri genişletme amacıyla kullanılır. Dilation işlemi, bir pikselin çevresindeki diğer pikselleri etkileyerek görüntüdeki nesneleri genişletir.

Genişleme işlemi, aşağıdaki adımlarla gerçekleştirilir:


1. Giriş görüntüsü ve yapılandırma elemanı belirlenir. Yapılandırma elemanı, genişletme işlemi sırasında hangi piksellerin etkileneceğini belirlemek için kullanılır. Yapılandırma elemanı, genellikle kare, dikdörtgen, daire veya çapraz gibi geometrik şekillere sahip olabilir.
2. Giriş görüntüsü üzerinde yapılandırma elemanı hareket ettirilir. Her bir piksel için yapılandırma elemanı ile çakıştırma (overlap) yapılır.
3. Yapılandırma elemanı ile çakışan piksellerin maksimum değeri alınır ve bu değer, genişletilmiş görüntünün ilgili pikselinin değeri olarak atanır. Bu işlem çevredeki nesnenin genişlemesine neden olur.
4. 2. ve 3. adımlar tüm pikseller üzerinde tekrarlanır, böylece genişletme işlemi tamamlanır.

Genişleme işlemi, görüntüdeki nesneleri genişletirken, nesnelerin sınırlarını daha belirgin hale getirir, küçük delikleri doldurur ve nesnelerin şeklini değiştirir. Yapılandırma elemanının boyutu ve şekli, genişletme işleminin sonucunu etkileyen faktörlerdir. Büyük bir yapılandırma elemanı daha fazla genişleme sağlarken, küçük bir yapılandırma elemanı daha ince detaylara etki edebilir [38-39].




Şekil 3.8. Soldaki görüntü HU +1000 ve üstü değerleri çıkartılmış görüntü, sağdaki görüntü erozyon ve genişleme sonrası elde edilen görüntü

Erozyon ve genişleme işlemlerinin sonucu Şekil 3.8’de verilmiştir. Şekil 3.8’deki soldaki görüntü OpenCV kütüphanesinin findContours ve approxPolyDP özelliği kullanarak erozyon ve genişleme sonrası görüntüde kalan gereksiz alanlar çıkarılarak elde edilmiş inme için gerekli olan beyin bölgesini göstermektedir. Beyin bölgesi elde edildikten sonra beyin maskesi de çıkartılmış olur. Şekil 3.9’da gerekli kısmın belirlenmesi, beyin çıkartılması ve maskin çıktısı gösterilmektedir.



Şekil 3.9. Sağdaki görüntü gerekli alanın belirlenmesi, soldaki görüntü alınması gereken alanın maski

Maskı çıkartılan görüntünün pixel değeri 0-1 aralığına getirilerek Şekil 3.7'deki orijinal görüntü ile çarpılır. Çarpma işlemi sonucunda kemik dokusu çıkartılmış sadece beyin kısmın bulunduğu alan elde edilir. Şekil 3.10'de kafatası bölgesi çıkartılmış beyin görüntüsü görülmektedir.



Şekil 3.10. Soldaki görüntü orijinal görüntü, sağdaki görüntü kafatası çıkartılmış görüntü


Şekil 3.10'dan da görülebileceği gibi görüntüler üzerinde sadece inmenin bulunacağı beyin dokusuna odaklanılmıştır. Daha sonra kafatası çıkartılmış görüntüler 512*512*3 olarak yeniden boyutlandırılmıştır. Boyutu değiştirilen görüntüler üzerinden görüntü iyileştirme çalışmaları yapılmıştır. Lineer normalizasyon yöntemi uygulanmıştır. Lineer normalizasyon, her veri noktası için yeni bir referans "bazı" oluşturmayı içerir. Genellikle "maksimum-minimum" normalizasyonu olarak adlandırılan bu teknik, analistlere kümedeki maksimum x değeri ile minimum x değeri arasındaki farkı alarak ve bir baz oluşturarak veriyi normalleştirmelerine olanak tanır. Normalizasyon yöntemi ile inme görüntüleri lineer yöntemle 0-1 aralığına sıkıştırılmıştır. Sıkıştırma yönteminden sonrasında verilerde kayıp oluşmamaktadır. Linear normalizasyon yöntemi uygulanarak görüntüler üzerinde farklı cihazlardan kaynaklı sayısal değer farklılığını kaldırılmış olur ve eğitim sırasında özellikler çıkartılırken sayısal değerler birbirlerine yakın olduğu için bölge tespitin bulunmasında başarı izlenilmektedir [40-41]. Linear normalizasyon formülü Eşitlik 3.1'de gösterilmektedir.

$$x_{normalized} = (x - min_x) / (max_x - min_x) \quad (3.1)$$

Burada:

x , normalleştirilecek olan veri noktası, min_x , veri setindeki minimum x değeri, max_x , veri setindeki maksimum x değeri, $x_normalized$, normalleştirilmiş x değeridir.

Bu eşitlik, her veri noktasını minimum ve maksimum değerler arasında ölçeklemek için kullanılır. Bu sayede, veri noktaları belirli bir aralığa sıkıştırılır ve farklı veri setleri arasında karşılaştırma yapmak daha kolay hale gelir. Şekil 3.11’de normalizasyon uygulanmış inme görüntüsü bulunmaktadır.



Şekil 3.11. Soldaki görüntü orijinal görüntü, sağdaki görüntü normalizasyon uygulanmış görüntü

Kafatası çıkartılmış ve normalizasyon uygulanmış görüntülere daha sonra CLAHE (Contrast Limited Adaptive Histogram Equazation) yöntemi kullanılarak histogram eşitleme (histogram equalization) uygulanmıştır [42-43].


CLAHE, görüntü iyileştirmede sıklıkla kullanılan bir histogram eşitleme yöntemidir. Görüntü kalitesi tüm görüntü histogramının yoğunluk dinamik aralığını genişleterek iyileştirilebilir. Histogram eşitleme, görüntünün yoğunluk dağılımını normalize ederek homojen bir yoğunluk dağılımına sahip sonuç görüntüsünü elde etmek için yapılır ve bu şekilde iyileştirme işlemi gerçekleştirilir.

Ancak, histogram eşitleme tüm görüntünün yoğunluk dağılımını kullanırken, ortalama yoğunluk seviyesi orta değere ayarlandığında bazı görüntülerde soluk bir etki oluşturabilir. Ayrıca, dar bir bölgede yoğun yoğunluk dağılımına sahip görüntülerde birçok gürültü pikselinin ortaya çıkmasına neden olabilir. Bu sorunları çözmek için yerel histogram eşitleme teknikleri geliştirilmiştir [43].

Adaptif histogram eşitleme, histogram eşitleme işlemini değiştirilmiş bir şekilde uygular ve yerel verilere optimizasyon yapar. Temel fikir, görüntünün bir ızgara şeklinde dikdörtgen bölgelere bölünmesidir ve her bölgeye standart histogram eşitleme uygulanır. Optimal bölge boyutları ve sayısı görüntüye bağlı olarak değişir [43].

Görüntü alt bölgelere bölündükten sonra her bir bölgeye histogram eşitleme uygulanır ve alt bölgeler, bi-lineer interpolasyon yöntemiyle birleştirilerek iyileştirilmiş bir bütün görüntü elde edilir. Ancak, adaptif histogram eşitlemede gürültü sorunu ortaya çıkar. Bunun önüne geçmek için homojen bölgelerde kontrast artırma sınırlandırılmalıdır ve bu amaçla kontrast sınırlı adaptif histogram eşitleme (CLAHE) yöntemi geliştirilmiştir [43].


CLAHE yönteminde görüntü karelere bölünmüş küçük bloklara ayrılır. AHE, her bir blok için histogramı eşitleştirir. Eğer zeminde biraz gürültü varsa, AHE gürültüyü artırır. Bu nedenle, bu sorunu önlemek için kontrast sınırlama kullanılır. Kontrast sınırlamasının üzerinde histogram bölünmeleri varsa, bu pikseller kesilir ve eşit bir şekilde dağıtılır. Eşitleme işleminden sonra, yapaylık etkisini azaltmak için lineer interpolasyon uygulanır. CLAHE yöntemiyle, gürültü etkisini artırmadan beyin görüntülerde kontrastı artırabilir [44]. CLAHE yönteminin uygulanma sebebi her görüntü üzerinde farklı ışıklandırmalar bulunmasıdır. Farklı cihazlardan elde edildiği tahmin edilen görüntüler cihaz kaynaklı farklı bir ışık dağılımı göstermiştir. Bunun için ön işlemlerden biri olarak histogram eşitleme işlemi yapılmıştır. Çıktıları Şekil 3.12’de görülmektedir.



Şekil 3.12. Soldaki görüntü normalizasyon uygulanmış görüntü, sağdaki görüntü normalizasyon üstüne CLAHE uygulanmış görüntü

3.4. Görüntü Çoğaltma

Bütün ön iyileştirme işlemleri yapıldıktan sonra eğitim sırasında görüntü sayısı az olduğu için ve CNN algoritmalarında veri fazlalığı ile daha iyi başarı aldığı gözlemlendiği için yaklaşık olarak her görüntü için rastgele +10,+5 ve -5,-10 yönde döndürme işlemi yapılarak veri çoğaltma işlemi yapılmıştır (Şekil 3.13).



Şekil 3.13. BT kesit görüntüsünün +10, +5 ve -5, -10 derece döndürülmüş halleri


3.5. ConvNext

ConvNeXt, Facebook AI Research (FAIR) tarafından 2022 yılında önerilen saf bir CNN'dir [45]. Bu model, pencere kaydırma ve göreceli konum önyargısı gibi zahmetli işlemlere ihtiyaç duymadan, mevcut popüler dönüştürücü ağlarından daha az hesaplama ile daha iyi performans sunar.

ConvNeXt'in genel yapısı, ResNet'in rezidüel bloklarını kullanarak tasarlanmıştır. Ayrıca, ağın genel performansını daha da iyileştirmek için birçok gelişmiş ağ tasarımı yaklaşımını da içermektedir. ConvNeXt-Tiny, ConvNeXt modelinin küçük bir versiyonudur. Çalışma mantığı, ResNet tabanlı bir yapıya sahip olmasıyla benzerlik gösterir [46].

ConvNeXt-Tiny modelin yapısı Şekil 3.14 A görüntüsünde gösterilmektedir. Model girişinde ilk olarak görüntüler alınır ve stem katmanında 7×7 yamalara (patchlere) ayrılarak hazır hale getirilir. Daha sonra ConvNext blok yapısında Şekil 3.14 B görüntüsünde gösterildiği gibi işlemler yapılmaya başlanır. Öncelikle Depthwise Conv kısmında görüntülerin RGB kanallarına ayrı ayrı evrişim işlemleri uygulanır, daha sonra bütün kanallar birleştirilir. Evrişim ağından çıkan matrise normalizasyon işlemi uygulanır ve daha sonra tekrar evrişim işlemi uygulanır. Ardından GELU aktivasyonu uygulanır ve görüntüler tekrar evrişim katmanına girer. Bu evrişim sonucunda elde edilen bazı filtreler Drop Path katmanından elenerek çıktı elde edilir. İlk görüntü ile bu çıktı birleştirilir. ConvNeXt-Tiny modelinde bu katman her basamakta 3 defa uygulanmaktadır. Bu katmandan sonra DownSample işlemi yani maksimum havuzlama (max pooling) işlemi uygulanmaktadır ve en sonda sınıflandırma işlemi gerçekleşir [46].


ConvNeXt-Tiny ve ConvNeXt Blok'un detaylı yapısı Şekil 3.14'te gösterilmektedir.



Şekil 3.14. (A) ConvNeXt-Tiny genel ağ yapısı; (B) ConvNeXt blok yapısı [46]

3.6. MultiResUNet

MultiResUNet, Nabil Ibteha ve arkadaşları tarafından [47] Bangladeş Teknoloji Üniversitesi'nde multimodal biyomedikal görüntü bölütleme için geliştirilen bir mimaridir. MultiResUNet, çok katmanlı bir sinir ağı mimarisi olan UNet'in genişletilmiş bir versiyonudur. Bu mimari, medikal görüntüleme için özellikle uygun olan, yüksek çözünürlüklü, çoklu etiketli yapıdadır ve bölütleme görevleri için tasarlanmıştır. MultiResUNet, UNet'in kodlayıcı-kod çözücü yapısını korur, ancak aynı zamanda MultiRes Blok ve Res yoluyla kodlayıcı katmanına birden fazla ölçek ekler. Bu ölçekler, her katmandaki çıktıları farklı boyutlara ölçekleyerek, ağın görüntü üzerindeki hem düşük hem de yüksek özellikleri yakalamasına olanak tanır. Böylece, MultiResUNet, daha iyi bölütleme sonuçları elde etmek için ağın özelliklerinin daha iyi öğrenilmesine yardımcı olur.



Şekil 3.15. MultiResUNet mimari yapısı


3.6.1. MultiResUNet mimarisi

MultiResUNet, dört kodlayıcı blok ve dört çözücü bloktan oluşan bir kodlayıcı-çözücü mimarisidir. Kodlayıcı ve çözücü, bir köprü aracılığıyla birbirlerine bağlanmıştır. Şekil 3.15'te MultiResUNet mimarisi gösterilmektedir. MultiResUNet'in mimarisi; giriş katmanı, kodlayıcı, geçiş katmanı, çözücü (dekodlayıcı) ve çıkış katmanından oluşmaktadır.

MultiRes blok

Kodlayıcı ve Dekodlayıcı kısımlardaki MultiRes Blok çalışma Şekil 3.16'da gösterilmektedir. MultiRes Blok, UNET mimarisinde kullanılan konvolüsyonel bloğun yerine geçen bir yapıdır. MultiRes Blok, iki adet 3×3 boyutunda konvolüsyonel katmandan oluşur ve ardından grup normalizasyonu (batch normalization) ve ReLU aktivasyon fonksiyonu uygulanır. MultiResUNet, üç adet 3×3 boyutunda konvolüsyonel katmandan oluşan bir seri bağlantı ile başlar. Her konvolüsyonel katmandan sonra grup normalizasyonu ve ReLU aktivasyonu uygulanır. Daha sonra, üç konvolüsyonel katmanın çıktılarını birleştirilir. Burada, ardışık olarak iki adet 3×3 boyutunda konvolüsyonel katmanı kullanılması, 5×5 boyutunda bir konvolüsyonu anımsatır. Üç adet 3×3 boyutunda konvolüsyonel katmanı ise 7×7 boyutunda bir konvolüsyonel katmanına benzer. Bu nedenle, daha büyük konvolüsyonel katmanı daha küçük 3×3 boyutunda konvolüsyonel katmanları ardışık dizisi şeklinde ifade edilmesi sağlanılır [47- 48].


Bu işlemten sonra, bir toplama bağlantısı (kimlik eşlemesi veya kısayol bağlantısı) gelir. Bu bağlantı, giriş ve birleştirilmiş özniteliklerin eleman bazında toplanmasını gerçekleştirir. Kimlik eşlemesi, gradyan akışının daha iyi olmasına yardımcı olur ve kaybolan gradyanlar sorununu çözer. Daha sonra, ReLU aktivasyon fonksiyonu ve Batch normalization katmanı uygulanır.



Şekil 3.16. a) UNet mimarisinde kullanılan konvolüsyonel blok yapısı b) MultiResUNet mimarisinde kullanılan MultiRes blok yapısı [48]

Res yolu (Res path)

Res Yolu (Res Path), U-Net mimarisinde bulunan basit atlama bağlantısının yerine geçen bir yapıdır. Kodlayıcı ve çözücünün öznitelikleri arasında bir anlamsal boşluk vardır. Bu nedenle, basit bir birleştirme işlemi işe yaramayabilir ve performans düşüklüğüne neden olabilir. Kodlayıcı ve çözücünün öznitelikleri arasındaki anlamsal boşluğu azaltmak için Res Yolu (Res Path) kullanılır. Kodlayıcı öznitelikleri, bir dizi Res Yolu'ndan geçirilir ve sonra Res Yolu'nun çıktısı çözücü öznitelikleriyle birleştirilir. Şekil 3.17'de Res Yolu Diagramı gösterilmektedir [47-48].



Şekil 3.17. Res yolu diyagramı [48]

3.6.2. Giriş katmanı


MultiResUNet mimarisindeki ilk katman, giriş katmanıdır. Bu katmanda, giriş görüntülerinin piksel boyutu şekillendirilir. Giriş görüntülerinin boyutları, eğitim ve test başarı oranını etkileyen bir faktördür. Yüksek boyutlu görüntülerin kullanıldığı girişler, modelin eğitim ve test aşamalarının süresini artırabilir, ancak modelin başarısını olumlu yönde etkileyebilir. Yüksek boyutlu görüntüler, daha fazla detay ve bilgi içerdikleri için modelin daha iyi özellikler öğrenmesine yardımcı olabilir. Öte yandan, düşük boyutlu görüntülerin kullanıldığı girişler, modelin eğitim ve test sürelerini azaltabilir, ancak modelin başarısını olumsuz etkileyebilir. Düşük boyutlu görüntüler, daha az detay ve bilgi içerdikleri için modelin daha az ayrıntıyı yakalaması ve daha az hassas sonuçlar üretmesi muhtemeldir. Bu nedenle, giriş görüntülerinin boyutları, modelin performansı üzerinde önemli bir rol oynar ve optimal boyutlar, yeterli bilgiyi içerecek ve modelin eğitim ve test sürelerini dengeleyecek şekilde seçilmelidir [49].

3.6.3. Konvolüsyon katmanı

Konvolüsyon katmanı, derin öğrenme ve sinir ağlarındaki önemli bir yapı taşıdır. Görüntü işleme ve ses işleme gibi alanlarda yaygın olarak kullanılır. Konvolüsyon katmanı, veri

üzerinde bir ya da birden fazla filtreyle konvolüsyon işlemi uygulayarak yeni özellik haritalarını çıkarmak için kullanılır.

Konvolüsyon işlemi, bir filtre matrisi ya da çekirdek matrisi ile veri üzerinde nokta çarpımı yaparak gerçekleştirilir. Filtre matrisi, giriş veri üzerinde kaydırılarak her bir konumda nokta çarpımı işlemi uygulanır (Şekil 3.18). Bu işlem sonucunda, giriş verinin belirli özelliklerini vurgulayan yeni bir özellik haritası elde edilir. Özellik haritası, giriş verinin çeşitli yönlerdeki kenarları, köşeleri, desenleri veya diğer özelliklerini temsil eder.



Şekil 3.18. Konvolüsyon çalışma şekli [50]

Konvolüsyon katmanının öğrenilebilir parametreleri, filtre matrisleridir. Bu filtre matrisleri, eğitim süreci boyunca optimize edilerek özellik çıkarma işleminin en iyi şekilde gerçekleştirilmesi sağlanır. Ayrıca, konvolüsyon katmanı genellikle aktivasyon fonksiyonu ve havuzlama (pooling) işlemi ile birlikte kullanılır. Aktivasyon fonksiyonu, özellik haritalarını geçmek için kullanılır ve non-linearite sağlar. Havuzlama işlemi ise özellik haritalarını boyut olarak küçültür ve özelliklerin transasyon ve ölçek değişikliklerine karşı daha dayanıklı olmasını sağlar.

Konvolüsyon katmanları, sinir ağlarının derinliğini artırmak ve daha karmaşık özellikleri öğrenmek için bir araç olarak kullanılır. Birden fazla konvolüsyon katmanı kullanılarak daha yüksek seviyeli özellikler elde edilir. Bu sayede, giriş verinin daha kapsamlı bir temsili elde edilebilir ve nihai sınıflandırma veya tahminleme işlemleri için daha iyi sonuçlar elde edilebilir.

3.6.4. Batch normalizasyon

Batch normalizasyon, Sergey Ioffe ve Christian Szegedy tarafından 2015 yılında önerilmiştir. İkili, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift" başlıklı makalede batch normalizasyon yöntemini tanıtmışlardır [51]. Bu makale, derin sinir ağlarının eğitimini hızlandırmak ve daha istikrarlı hale getirmek için batch normalizasyonun etkilerini ayrıntılı bir şekilde açıklamıştır. Bu çalışma, normalizasyonunun popüler hale gelmesini sağlamış ve birçok derin öğrenme modelinde yaygın bir şekilde kullanılan bir teknik haline gelmiştir.

Batch normalizasyon, yapay sinir ağlarının eğitim sürecinde hızlı ve istikrarlı bir şekilde ilerlemesini sağlamak için kullanılan bir yöntemdir. Bu yöntem, her katmandaki girdilerin normalleştirilmesini sağlayarak, eğitim sürecindeki değişkenlikleri azaltır.

Batch normalizasyonun iki ana işlevi vardır [51]:

- **Girdilerin Normalleştirilmesi:** Batch normalizasyon, her bir katmanın girdilerini ölçeklendirerek ve merkezleyerek normalleştirir. Bu işlem, girdi dağılımını daha istikrarlı hale getirir ve ağın daha tutarlı bir şekilde öğrenmesini sağlar.
- **İçsel Kovaryans Kaymasının Azaltılması:** İçsel kovaryans kayması, ağın her bir katmanında gerçekleşen parametre başlangıcı ve girdi dağılımındaki değişiklikler nedeniyle ortaya çıkar. Batch normalizasyon, bu kovaryans kaymasını azaltarak ağın daha hızlı ve daha etkili bir şekilde öğrenmesini sağlar.

Batch normalizasyonun faydaları şunlardır [51]:

- **Eğitim sürecini hızlandırır:** Batch normalizasyon, gradyanların daha tutarlı bir şekilde ilerlemesini sağlayarak eğitim sürecini hızlandırır. Bu durum daha az eğitim iterasyonu gerektirir ve daha hızlı bir şekilde daha iyi sonuçlar elde edilmesini sağlar.
- **Ağın daha istikrarlı olmasını sağlar:** Batch normalizasyon, ağın girdilerini normalleştirerek değişkenliği azaltır. Bu da ağın daha istikrarlı bir şekilde öğrenmesini sağlar ve aşırı öğrenme riskini azaltır.

- Daha genelleyici modeller elde edilmesini sağlar: Batch normalizasyon, ağıın genelleme yeteneğini artırır. Daha iyi genelleme yapabilen modeller elde etmek için kullanılan bir tekniktir.

Sonuç olarak, batch normalizasyon, yapay sinir ağlarının daha hızlı ve daha istikrarlı bir şekilde eğitilmesini sağlayarak performanslarını artıran etkili bir yöntemdir.

3.6.5. Düzleştirilmiş doğrusal birim katmanı (Rectified linear units layer(ReLU))


ReLU'nun günümüzdeki popüler formülasyonu, 2010 yılında Vinod Nair ve Geoffrey E. Hinton tarafından "Rectified Linear Units Improve Restricted Boltzmann Machines" başlıklı bir makalede tanıtıldı [52]. Bu çalışma ReLU'nun derin öğrenme modellerinde kullanımının avantajlarını vurgulayarak, daha önceki aktivasyon fonksiyonlarına göre daha iyi sonuçlar verdiğini göstermiştir.

ReLU, düzeltilmiş doğrusal aktivasyon birimi anlamına gelir ve derin öğrenme devrimindeki birkaç dönüm noktasından biri olarak kabul edilir. Sigmoid veya tanh gibi önceki aktivasyon işlevlerinden basit ama gerçekten daha iyi. Relu formülü;

$$f(x) = \max(0, x) \quad (3.2)$$

ReLU fonksiyonu ve türevidi monotoniktir. Fonksiyon, herhangi bir negatif giriş alırsa 0 değerini döndürür, ancak herhangi bir pozitif değer x için giriş değerini geri döndürür. Bu nedenle, 0'dan sonsuza kadar olan bir aralıkta çıktı verir [53]. Eşitlik 3.3'de ifade edildiği gibi Şekil 3.19'de da grafiği gösterilmiştir. Şekil 3.20'da ise ReLU'nun görüntü üzerinde etkisi gösterilmektedir.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.3)$$



Şekil 3.19. ReLU grafiği



Şekil 3.20. ReLU örnek görüntü [49]

3.6.6. Maksimum havuzlama katmanı (Max pooling layer)

Pooling layer, genellikle evrişimli katmanların ardından kullanılan bir katmandır. Evrişimli katmanlardan elde edilen özellik haritalarını özetlemek ve boyutlarını azaltmak için kullanılır. Bu katmanda, özellik haritaları bölgesel olarak incelenir ve her bölgenin özet bilgisi alınarak boyutları küçültülür. Bu işlem, ağıın yerel özelliklere karşı daha ince hassasiyetini korumasını sağlar ve aşırı öğrenme riskini azaltır [54].

Havuzlama katmanı, aynı zamanda translasyonel invariyan (translational invariance) özelliği sağlar. Yani, özelliklerin bir miktar kayması veya yer değiştirmesi durumunda, havuzlama işlemi sonucunda elde edilen özetlerin değişmemesi beklenir. Bu da ağıın görüntülerin konumlarına bağlı olmayan özellikler öğrenmesine yardımcı olur.


Havuzlama katmanı, daha sonra CNN'lerin bir standart bileşeni haline gelmiştir ve genellikle özellik çıkarım sürecinin ardından kullanılır. Bu katman, ağıın boyutunu azaltırken önemli özellikleri korumaya yardımcı olur ve ağıın genelleme yeteneğini artırır.

Maksimum havuzlama katmanı, havuzlama katmanının bir türüdür ve özellik haritasındaki bilgilerin boyutunu azaltmak için kullanılır. Havuzlama katmanı işlemi, her çekim alanında en büyük değeri seçerek çalışır [55].

Maksimum havuzlama katmanının işlevleri şunlardır [55]:

1. Boyut Azaltma: Maksimum havuzlama, özellik haritasındaki boyutu azaltır. Özellik haritası üzerinde bir çekirdek (genellikle 2x2 veya 3x3 boyutunda) hareket ettirilir ve her çekim alanında en büyük değeri seçilerek yeni bir çıktı haritası oluşturulur. Bu şekilde, girişin boyutu küçülür ve daha derin katmanlarda daha az parametreye ihtiyaç duyulur.
2. Özellik Çeşitliliği: Maksimum havuzlama, özellik haritasında bulunan farklı özelliklerin çeşitliliğini korur. En büyük değeri seçme işlemi, özelliklerin en belirgin olanlarını vurgular ve önemli bilgi kaybını önler. Bu sayede, ağıın daha genel ve ayırt edici özellikleri öğrenmesi sağlanır.
3. Translasyonel İnvarians: Maksimum havuzlama, nesnelerin konumlarının değişmesi durumunda da etkili çalışabilir. En büyük değeri seçerek çalışması, nesnenin konumunun değişmesi durumunda bile en belirgin özelliğin korunmasına yardımcı olur. Bu durum özelliklerin nesnelerin yer değiştirmelerine karşı daha ince ayarlanmamış olmasını sağlar.

Maksimum havuzlama, özellik çıkarım sürecinde kullanılarak hesaplama maliyetini azaltır, ağıın yerel özelliklere karşı hassasiyetini artırır ve aşırı uyum riskini azaltır (Şekil 3.21). Ancak, maksimum havuzlama işlemi bazı bilgi kaybına neden olabilir, çünkü diğer değerleri göz ardı ederek sadece en büyük değeri seçer.



Şekil 3.21. Max pooling çalışma şekli [55]

3.6.7. Birleştirme (Concatenate)

Birleştirme işlemi, sinir ağlarında özelliklerin birleştirilmesi için kullanılan bir operasyondur. Temel olarak, farklı özelliklerin bir araya getirilerek daha kapsamlı bir temsil elde edilmesini sağlar. [56]

Birleştirme'nin bazı kullanım amaçları [56]:

1. **Özellik Birleştirme:** Farklı katmanlardan veya farklı özellik haritalarından gelen özellikleri birleştirmek için kullanılır. Örneğin, evrişimli sinir ağlarında, farklı evrişim katmanlarının çıktılarını birleştirerek daha zengin bir özellik haritası oluşturulabilir. Bu, ağın daha karmaşık özellikleri daha iyi öğrenmesine yardımcı olur.
2. **Paralel İşlem:** Birden fazla paralel yolun olduğu ağ yapılarında, her yolun çıktılarını birleştirerek birden çok kaynaktan gelen bilgileri entegre etmek için kullanılır. Bu, ağın birden çok bilgi kaynağını etkili bir şekilde kullanmasını sağlar.
3. **Özgün Bilgileri Koruma:** Özelliklerin birleştirilmesi, özgün bilgilerin korunmasına yardımcı olabilir. Örneğin, bir ağda bulunan birden çok özellik haritasının birleştirilmesi, her bir haritanın özgün özelliklerini korurken, ağın daha kapsamlı bir temsil oluşturmasına olanak tanır.
4. **Boyut Uyumu:** Birleştirme işlemi, farklı boyutlara sahip özelliklerin bir araya getirilmesini sağlar. Özellikler farklı boyutlarda olabilirken, birleştirme işlemiyle birlikte aynı boyutta birleştirilebilirler.

Bu şekilde, birleştirme işlemi, sinir ağlarında özelliklerin etkili bir şekilde birleştirilmesini, daha zengin temsillerin elde edilmesini ve ağı daha güçlü bir performans sergilemesini sağlar.

3.6.8. Tam bağlantılı katman (Fully connected layer)

Tam bağlantılı (fully connected) katman, sinir ağlarının temel yapı taşlarından biridir ve yaygın olarak kullanılan bir bileşendir. Tam bağlantılı katman, her girdi özelliğini tüm çıkış nöronlarına bağlayan ağırlıklar ve bir aktivasyon fonksiyonundan geçiren bir işlemi ifade eder [57].

Tam bağlantılı katmanlar, sinir ağlarının klasik yapılarında sıklıkla kullanılır. Özellikle sınıflandırma veya regresyon gibi çıktı üretmek için son katmanda kullanılırlar. Tam bağlantılı katmanlar, ağı özelliklerin birleşik bir temsilini oluşturmasını sağlar ve sınıflandırma veya regresyon gibi görevler için kararları yapısallaştırır [9].

Tam bağlantılı katmanlar, temel olarak sinir ağlarının matematiksel formülasyonunda yer alır ve çeşitli derin öğrenme kütüphaneleri ve çerçeveleri tarafından desteklenir. Bu katmanlar, birçok araştırmacı ve geliştirici tarafından kullanılır ve özellikle çok katmanlı yapay sinir ağlarının geleneksel yapısında önemli bir bileşen olarak kabul edilir.

ESA mimarisinde peş peşe gelen konvolüsyon, ReLu ve havuzlama katmanlarının peşinden tam bağlantılı katman gelir. Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır. Farklı sinir ağı mimarilerinde tam bağlantılı katmanların sayısı değişebilir. Tam bağlantılı katman, her bir giriş biriminin kendisinden önceki katmandaki tüm birimlerle bağlantılı olduğu bir yapıdır. Örneğin, verilen bir sinir ağı mimarisi olan ESA mimarisinde, son katmanın çıktıları $25 \times 25 \times 256$ boyutunda bir matris olarak düşünelim. Bu matrisi 160,000 birimlik tek bir sütun vektörüne dönüştürdüğümüzü varsayalım [9].

Tam bağlantılı katmanın boyutunu 4096×1 olarak belirlediğimizi düşünelim. Bu durumda, her bir 160,000 birimlik giriş vektörü, 4096 birimlik tam bağlantılı katmana bağlanır. Bu

bağlantı, her bir giriş biriminin tam bağlantılı katmandaki her bir birimle bağlantılı olduğu anlamına gelir [9].

Toplamda, bu sinir ağı mimarisinde 160,000x4096 ağırlık matrisi oluşur. Her bir 160,000 birim, 4096 birimle bağlantılıdır ve bu bağlantılar, ağırlık matrisinde temsil edilir. Bu sebeple, bu katmana tam bağlantılı katman denir [9].

Tam bağlantılı katman, her bir giriş biriminin tüm çıktı birimleriyle bağlantılı olduğu için, bu yapıda çok sayıda parametre bulunur. Bu durum, ağı hesaplama ve bellek gereksinimlerini artırır. Bu nedenle, tam bağlantılı katmanlar, daha küçük boyutlu özellik haritalarından veya özellik çıkarma katmanlarından gelen girişleri düzleştirmek ve daha yüksek seviyeli özelliklerin temsilini sağlamak için kullanılır.

3.6.9. Kayıp fonksiyonları

Bu bölümde sınıflandırma problemlerinde kullanılan kayıp fonksiyonları tanıtılmıştır. İkili çapraz entropi, kategorik çapraz entropi ve seyrek kategorik çapraz entropi bu kayıp fonksiyonları arasında yer alır [58].

İkili çapraz entropi, yalnızca iki sınıflı sınıflandırma problemlerinde kullanılır. Bu kayıp fonksiyonu, modelin tahmin ettiği olasılıkları gerçek etiketlere yaklaştırmayı hedefler. İkili çapraz entropi kaybı, doğru sınıflandırma için minimum değeri (0) alırken, yanlış sınıflandırma durumlarında kaybın artmasını sağlar [58].

Kategorik çapraz entropi ve seyrek kategorik çapraz entropi, iki veya daha fazla sınıflı sınıflandırma problemlerinde kullanılır. Bu kayıp fonksiyonları, etiketlerin ve tahminlerin olasılık dağılımlarını karşılaştırarak modeli eğitir. Kategorik çapraz entropi kaybı, etiketlerin one-hot encoding şeklinde temsil edildiği durumlarda kullanılır. Her sınıf için bir etiket vektörü oluşturulur ve bu kayıp fonksiyonu, modelin tahmin ettiği olasılıkları gerçek etiketlere yaklaştırmayı hedefler [58].

Seyrek kategorik çapraz entropi ise etiketlerin doğrudan one-hot encoding ile temsil edilmediği, ancak etiketlerin indekslerinin doğrudan kullanıldığı durumlarda tercih edilir. Bu durumda, etiketlerin doğrudan indekslerle temsil edildiği için daha az bellek kullanımı

sağlanır. Seyrek kategorik çapraz entropi kaybı, modelin tahminlerini gerçek etiketlere yaklaştırmayı amaçlar [58].

Bu şekilde ifade edildiğinde, kategorik çapraz entropi ve seyrek kategorik çapraz entropi aynı temele dayanır, ancak etiket temsilindeki farklılık nedeniyle seyrek kategorik çapraz entropi kullanılır. Eğer etiketler one-hot encoding ile temsil edilirse, kategorik çapraz entropi kullanılması gerekmektedir.

3.6.10. Optimizasyon algoritmaları

Bu bölümde, farklı optimizasyon algoritmaları hakkında bilgiler aktarılmıştır. Bu algoritmalar, makine öğrenimi ve derin öğrenme modellerinin eğitiminde kullanılan parametre güncelleme yöntemleridir [59].

- Olasılıksal Eğim Düşümü (SGD): Eğitim aşamasında kullanılan veriler rastgele seçilir ve her eğitim örneği için parametreler güncellenir.
- Adaptif Gradyan (Adagrad): Öğrenme oranı, sık değişen parametreler için küçülürken, az değişen parametreler için büyüme eğilimi gösterir. Ancak bu algoritmanın dezavantajı, öğrenme oranının eğitim sürecinde çok küçük hale gelmesidir.
- Adadelata: Adagrad'ın öğrenme oranının aşırı küçülmesini engellemek için geliştirilmiştir. Bu algoritma, eğitim aşamasının başında öğrenme oranını belirlemeye ihtiyaç duymaz.
- Kare Ortalamalarının Karekökü Yayılımı (RMSprop): Adadelata algoritmasıyla birlikte geliştirilen bu algoritma, Adagrad'ın öğrenme oranının aşırı küçülmesini düzeltmek için kullanılır.
- Adaptif Moment Tahmin (Adam): Adam algoritması, Adadelata algoritmasına benzer bir yapıya sahiptir. Ancak öğrenme oranı yanında momentum değişikliklerini de bellekte tutar.
- Adamax: Adam algoritmasının bir varyantıdır. Bu algoritma, Adam algoritmasını daha etkin hale getirmek için geliştirilmiştir.
- Nesterov Hızlandırılmış Adaptif Moment Tahmin (Nadam): Nadam algoritması, Adam algoritmasına benzer bir yapıya sahiptir. Ancak bu algoritma, eğim

hesaplanmadan önce eğitim parametrelerini momentumla birlikte günceller, böylece daha doğru ilerlemeler elde edilir.

Bu algoritma çeşitleri, modelin eğitimi sırasında parametrelerin nasıl güncelleneceğini belirler ve genellikle eğitim sürecinin hızını ve performansını iyileştirmek için kullanılır.

3.6.11. Epok, küme boyutu ve öğrenme oranı

Epok, bir ESA mimarisindeki tüm katmanlarda ileri ve geri yönde işleme uğrama sayısıdır. Yüksek bir epok sayısı, daha yüksek bir başarı oranı elde edileceği anlamına gelmez. Genellikle belirli bir epok değerinden sonra ESA modellerinin öğrenme hızı yavaşlar. Ayrıca, yüksek epok değerleri modelin eğitim süresini uzatır. Bu soruna çözüm olarak erken durdurma yöntemi kullanılabilir [59].

Küme boyutu, verisetindeki görsellerin belirli bir küme boyutu set değerinde eğitim aşamasına dahil edilmesidir. Yüksek bir küme boyutu seçilirse daha fazla işlem hafızası gereklidir. Ancak yüksek değerlerde seçilen küme boyutuyla her bir epok arasındaki başarı oranı birbirine yakındır. Genellikle küme boyutları 2'nin katları şeklinde kullanılır. Epok ve küme boyutu arasında bir iterasyon ilişkisi vardır. Örneğin, toplamda 5210 görselin bulunduğu bir veri seti için küme boyutu 128 olarak alınırsa her bir epokta 40 iterasyon gerçekleşir [59].

ESA modellerinde ağırlıkların güncellenmesi geri yayılım (geriye doğru hesaplama) yöntemiyle sağlanır. Geri yayılımda, ağırlık güncellemesi, zincir kuralıyla türevin hesaplanması ve bu fark değerinin öğrenme oranı hiperparametresiyle çarpılmasıyla gerçekleştirilir. Öğrenme oranı sabit bir değer olarak alınabilir veya belirli sayıdaki epoklarda belirli bir oranda azaltılarak ayarlanabilir. Örneğin, minimum öğrenme oranı 0,001 olarak kabul edilirse, her 3 epokta bir 0,5 öğrenme oranı azaltma faktörüyle öğrenme oranı 0,00001'e kadar azaltılabilir. Adaptif algoritmalar bu tür yöntemleri sağlarlar [59].

3.7. Model Performansının Değerlendirilmesi

Sınıflandırma modellerinin performans karşılaştırmasında doğruluk (Eşitlik 3.4), kesinlik (Eşitlik 3.5), duyarlılık (Eşitlik 3.6), özgüllük (Eşitlik 3.7) ve F1 skoru (Eşitlik 3.8)

kullanılmıştır. Gerçek pozitif (TP), doğru sınıflandırılmış pozitif sınıfı sayısını ifade eder. Gerçek negatif (TN), doğru sınıflandırılmış negatif sınıf sayısını ifade eder. Yanlış pozitif (FP), yanlış sınıflandırılmış pozitif sınıf sayısını ifade eder. Yanlış negatif (FN) ise yanlış sınıflandırılan negatif sınıf sayısını ifade eder. Bölütleme modellerin performans karşılaştırmalarını da Dice katsayısı (Eşitlik 3.9) ve Jaccard indeksi (Eşitlik 3.10) kullanılmıştır.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3.22. Karışıklık matrisi [60]

Doğruluk (Accuracy)

Doğruluk, makine öğrenimi ve derin öğrenme sınıflandırma algoritmalarının performansını ölçmek için kullanılan temel bir ölçüdür. Doğruluk skoru, modelin eksiksiz bir test veri kümesi üzerinde doğru tahminlerinin sayısının toplam veri sayısına bölünmesiyle hesaplanır. Doğruluk skoru, genellikle 0 ile 1 arasında değer alır ve 1'e yaklaştıkça modelin başarılı olduğunu gösterir. Yani, yüksek doğruluk skoruna sahip bir model, veri kümesindeki doğru tahminleri yüksek oranda gerçekleştirir [61].

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.4)$$

Doğruluk skoru, Eşitlik 3.4'teki gibi ifade edilebilir. Bu tanımlama, doğruluk skorunun modelin doğru tahminlerinin toplam veri sayısına oranı olduğunu belirtir. Örneğin, doğru

tahminlerin sayısı 1000 ve toplam veri sayısı 1200 ise, doğruluk skoru $1000/1200 = 0,833$ olarak hesaplanır.

Doğruluk skoru, sınıflandırma problemlerinde modelin genel performansını değerlendirmek için kullanılır. Ancak, dengesiz sınıf dağılımları veya hatalı sınıflandırma maliyetleri gibi durumlarda doğruluk skoru tek başına yeterli olmayabilir. Bu durumlarda, diğer performans metrikleri veya özelleştirilmiş değerlendirme yöntemleri kullanılabilir.

Duyarlılık (Sensitivity)

Duyarlılık sınıflandırma problemlerinde gerçek pozitiflerin doğru bir şekilde tespit edilme oranını ifade eden bir performans ölçüsüdür. Duyarlılık, aynı zamanda gerçek pozitif oranı (TPR - True Positive Rate) veya hassasiyet (recall) olarak da adlandırılır. Duyarlılık, pozitif sınıfa ait olan veri noktalarının ne kadarının doğru bir şekilde tanınabildiğini gösterir. Eşitlik 3.5 ile hesaplanır [61].

$$\text{Duyarlılık (Sensitivity)} = TP / TP + FN \quad (3.5)$$

Duyarlılık skoru, 0 ile 1 arasında bir değer alır ve 1'e yaklaştıkça modelin pozitif veri noktalarını daha iyi tespit ettiğini gösterir. Yani, yüksek duyarlılık skoruna sahip bir model, pozitif sınıfa ait veri noktalarını yüksek oranda doğru bir şekilde tanır. Duyarlılık, genellikle hastalık tespiti, anormallik tespiti gibi durumlarda önemlidir. Bu tür durumlarda, yanlış negatif sonuçlar büyük bir öneme sahip olabilir, bu yüzden duyarlılık skorunun yüksek olması tercih edilir. Ancak, duyarlılık skoru yüksek olan bir modelde yanlış pozitif sonuçlar da artabilir, bu nedenle doğruluk ve diğer performans metrikleriyle birlikte değerlendirme yapmak önemlidir.

Kesinlik (Precision)

Kesinlik (precision), sınıflandırma problemlerinde pozitif olarak tahmin edilen veri noktalarının gerçekten pozitif olma oranını ifade eden bir performans ölçüsüdür. Kesinlik, yanlış pozitiflerin (false positive) oranını düşürmeyi hedefler ve yanlış alarm verme riskini azaltır [61]. Eşitlik 3.6 ile hesaplanmaktadır.

$$\text{Kesinlik (Precision)} = TP / TP + FP \quad (3.6)$$

Kesinlik skoru, 0 ile 1 arasında bir değer alır ve 1'e yaklaştıkça modelin pozitif olarak tahmin ettiği veri noktalarının gerçekten pozitif olma oranının yüksek olduğunu gösterir. Yüksek kesinlik skoruna sahip bir model, pozitif olarak tahmin ettiği veri noktalarının çoğunun gerçekten pozitif olduğunu gösterir. Kesinlik, yanlış pozitif sonuçların kabul edilemez olduğu durumlarda önemlidir. Örneğin, bir tıbbi teşhis uygulamasında yanlış bir şekilde bir hastalığı teşhis etmek, yanlış bir alarm durumunda olduğunda olumsuz sonuçlara yol açabilir. Bu durumlarda, kesinlik skorunun yüksek olması istenir.

Kesinlik skoru, diğer performans metrikleriyle birlikte değerlendirilmelidir. Özellikle, duyarlılık (sensitivity) gibi başka bir performans ölçüsü ile birlikte değerlendirildiğinde, bir denge kurulabilir ve sınıflandırma modelinin genel performansı daha iyi anlaşılabilir.

Özgüllük (Specificity)

Özgüllük, bir testin, belirli bir durumu olmayan bireyleri doğru bir şekilde tanımlama yeteneğini ölçer. Özgüllük, gerçek negatif sonuçların (belirli bir durumu olmayan bireylerin doğru bir şekilde tanımlandığı) oranını ifade eder [60]. Eşitlik 3.7 ile hesaplanmaktadır

$$\text{Kesinlik (Precision)} = TN / TN + FP \quad (3.7)$$

F1 skor

F1 skoru, bir sınıflandırma modelinin kesinlik (precision) ve duyarlılık (recall) performansını dengede değerlendiren bir ölçüdür. F1 skoru, bu iki performans metriğini tek bir değerde birleştirerek modelin genel sınıflandırma performansını değerlendirmek için kullanılır [61]. Eşitlik 3.8 ile hesaplanır.

$$F1 = 2 \times \text{Kesinlik} \times \text{Duyarlılık} / (\text{Kesinlik} + \text{Duyarlılık}) \quad (3.8)$$

F1 skoru, 0 ile 1 arasında bir değer alır ve 1'e yaklaştıkça modelin daha iyi bir denge sağladığını gösterir. Yüksek F1 skoruna sahip bir model, hem pozitif olarak tahmin ettiği

veri noktalarının gerçekten pozitif olma oranının yüksek olduğunu hem de gerçek pozitif veri noktalarının doğru bir şekilde tespit edildiğini gösterir. F1 skoru, özellikle dengeli sınıflar veya yanlış pozitifler ve yanlış negatifler arasında bir denge gerektiren durumlarda kullanışlıdır. Örneğin, bir hastalığın teşhisi gibi durumlarda hem yanlış teşhislerin hem de hastalığın kaçırılmasının önemli sonuçları olabilir. Bu durumlarda, F1 skorunun yüksek olması tercih edilir.

F1 skoru, diğer performans metrikleriyle birlikte değerlendirilmelidir. Özellikle, veri setinin dengesine, sınıf dağılımına ve önceliklere bağlı olarak, kesinlik ve duyarlılık arasında bir denge kurmak gerekebilir.

Dice katsayısı (Dice coefficient)

Dice katsayısı benzerlik ölçüsü olarak kullanılan ve özellikle görüntü işleme ve görüntü bölütleme alanlarında sıklıkla kullanılan bir metriktir. İki küme veya bölgenin ne kadar örtüştüğünü veya birbirine benzediğini ölçmek için kullanılır. Dice katsayısı, 0 ile 1 arasında değer alır ve 1'e yaklaştıkça benzerlik artar. 0 değeri ise hiçbir örtüşme olmadığını veya hiçbir benzerlik bulunmadığını gösterir. Eşitlik 3.9'daki gibi hesaplanır [62].

$$Dice = 2 \times \frac{|M \cap N|}{|M| + |N|} = 2 \times \frac{TP}{FP + FN + 2TP} \quad (3.9)$$

Jaccard indeksi

Jaccard İndeksi, küme benzerliğini ölçmek için kullanılan bir metriktir. Özellikle veri kümesi veya bölge tabanlı bölütleme problemlerinde yaygın olarak kullanılır. Jaccard İndeksi, iki kümenin kesişim kümesinin birleşim kümesine oranını hesaplar. Jaccard İndeksi, 0 ile 1 arasında değer alır ve 1'e yaklaştıkça benzerlik artar. 0 değeri ise hiçbir örtüşme olmadığını veya hiçbir benzerlik bulunmadığını gösterir. Eşitlik 3.10 ile formüle edilir [62].

$$Jaccard = \frac{|M \cap N|}{|M \cup N|} = \frac{TP}{TP + FP + FN} \quad (3.10)$$

4. DENEYSEL ÇALIŞMA VE BULGULAR

Bu çalışmada inme görüntüleri sınıflamak ve bölütleme için iki farklı senaryo izlenmiştir. Bu senaryolar;


- 1- Görüntü bölüm 3.3 ve bölüm 3.4'teki ön işlemler uygulanarak hazır hale getirilir. Görüntü üzerinde ilk olarak inme var mı yok mu sınıflandırma işlemi uygulanır. Bu sınıflandırma sonucunda inme varsa görüntü bölütleme modeli MultiResUNet'te girdi olarak kullanılıp inme olan bölgelerin belirlenmesi sağlanmıştır. Ardından elde edilen bölütleme bölgesi hangi tür inme olduğunu göstermek için iskemik ve hemorajik sınıflandırıcı modelinde girdi olarak kullanılıp inmenin türü tespit edilmiştir.
- 2- İkinci senaryo olarak görüntü bölüm 3.3 ve bölüm 3.4'teki ön işlemler uygulanarak hazır hale getirilir. Ön işlemleri yapılmış görüntü 3 sınıflı sınıflandırıcıda girdi olarak kullanılıp inme yok, iskemik inme ve hemorajik inme şeklinde sınıflandırılmıştır. Bu sınıflandırmadan elde edilen inme türü bilgisine göre görüntü iskemik inme durumunda iskemik inme bölütleme modelinde, hemorajik inme durumunda ise hemorajik inme bölütleme modelinde girdi olarak kullanılıp inme olan bölgeler bölütlenmiştir.

Sınıflandırma modellerinde eğitim aşamasında kullanılan parametreler; kayıp fonksiyonu olarak çapraz entropi, optimize edici olarak Adam, batch size 2 ve epoch 50 olarak ayarlanmıştır. Başlangıç öğrenme oranı olarak $3e-4$ olarak belirlenmiştir. Modellerin sınıflandırma performansı 7 dönem boyunca gelişme göstermediyse, öğrenme oranı 0,1 ile çarpılmıştır. Bölütleme modelinde eğitim aşamasında kullanılan parametreler ise; kayıp fonksiyonu olarak ikili çapraz entropi, optimize edici olarak Adam, batch size 5 ve epoch 250 olarak ayarlanmıştır. Başlangıç öğrenme oranı olarak $1e-3$ olarak belirlenmiştir. Çalışmalarda Python programlama dili ve sınıflandırmada PyTorch kütüphanesi, bölütlemede Tensorflow kütüphanesi ile NVIDIA GeForce RTX 3090 ekran kartı kullanılmıştır.


4.1. Senaryo 1

Bölüm 3.2'deki veri setinde bulunan görüntüler inme var ve inme yok sınıflandırma işlemi eğitimi için Bölüm 3.3'teki ön işlemler uygulanarak hazır hale getirilmiştir. Total de 7683

adet inme bulunduran ve 6804 adet inme bulundurmayan görüntü eğitim için kullanılmıştır. Bu sınıflandırma için dört farklı model kullanılmıştır. Bu modeller ConvNeXt_Tiny, ResNet50d, EfficientNet_b0 ve ResNeXt101_32x8d modelleridir. Modellerin eğitim başarıları sırasıyla 0,982, 0,972, 0,971, 0,946 olmuştur. Modellerin eğitim başarıları (accuracy) ve kayıp (loss) değerleri Şekil 4.1’de gösterilmektedir. %20 oranında kullanılan test görüntüleri için modellerden elde edilen sonuçlar Çizelge 4.1’de ve modellerin karışıklık matrisleri (confusion matrixleri) Şekil 4.2’de sunulmuştur. Tablo 4.2’de ise modellerin hızı bir görüntünün sınıflandırılması için harcadığı saniye cinsinden gösterilmiştir.




a) Sınıflandırma modellerinin eğitim başarı grafikleri



b) Sınıflandırma modellerinin kayıp grafikleri

Şekil 4.1. Sınıflandırma modellerinin a) eğitim başarı ve b) kayıp grafikleri



Şekil 4.2. Sınıflandırıcı Modellerin Karışıklık Matrisleri

Çizelge 4.1. Sınıflandırıcı modellerinin inme var ve inme yok sınıflandırma sonuçları

Model	Görüntü Sayısı	Kesinlik (Precision)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	F1-Skor	Doğruluk (Accuracy)
ConvNeXt_Tiny	1260	0,99	0,99	0,98	0,99	0,98
ResNet50d	1260	0,96	0,98	0,97	0,97	0,96
EfficientNet_b0	1260	0,93	0,99	0,98	0,96	0,95
ResNeXt101_32x8d	1260	0,90	0,95	0,91	0,93	0,90

Çizelge 4.2. Sınıflandırıcı modellerin ortalama sınıflandırma süresi

Model	Sınıflandırma Ortalama Süresi (sn)
ConvNeXt_Tiny	0,055
ResNet50d	0,076
EfficientNet_b0	0,047
ResNeXt101_32x8d	0,213

Çizelge 4.1'deki sonuçlar incelendiğinde ConvNeXt_Tiny modelinin inme var ve inme yok sınıflandırmasında en iyi sonucu verdiği gözlemlenmiştir. Çizelge 4.2'de hız konusunda EfficienNet_b0 modeli daha hızlı olmasına rağmen başarısı ile birinci ve hız konusunda ikinci sırada olan ConvNeXt_Tiny'nin inme var ve inme yok sınıflandırmasında iyi bir model olduğu görülmektedir. Bu nedenle çalışmanın devamında sınıflandırma işlemi için ConvNeXt_Tiny kullanılmasına karar verilmiştir.

Sınıflandırma sonucu elde edildikten sonra inme olan görüntüler bölütleme işlemine gidebilmesi için bölütleme çalışması yapılmıştır.

Bölütleme için görüntüler bölüm 3.3 ve bölüm 3.4'deki ön işlemler yapıldıktan sonra bölüm 3.6'da anlatılan MultiResUNet modelinde eğitim girdisi olarak kullanılmıştır. Bu aşamada inme türüne bakmaksızın bölütleme eğitimi gerçekleştirilmiştir. Bölütleme eğitiminde 7683 görüntü kullanılmıştır. Eğitim başarısı 0,81'dir.

Bölütleme testi için 382 adet iskemik ve 416 adet hemorajik görüntü kullanılmıştır. Elde edilen başarı skorları Çizelge 4.3'de gösterilmiştir. Yapılan çalışma sonucu hemorajik inme türünde bölütleme başarısının daha yüksek olduğu görülmüştür.


Çizelge 4.3. İskemik ve hemorajik inmenin bölütleme test sonuçları

	Jaccard	Dice
İskemik	0,47	0,59
Hemorajik	0,52	0,67


Şekil 4.3'de eğitim sırasında doğrulama (validasyon) görüntülerinden elde edilen örnek çıktılar gösterilmektedir. Girdi görüntüsü, inme bölgesini gösteren maske görüntüsü ve modelin tahmin sonucu gösterilmiştir.

Şekil 4.4 iskemik veya hemorajik şeklinde inme türüne bakılmaksızın MultiResUNet ile yapılan bölütleme işleminin iskemik test görüntüleri üzerindeki sonuçlarını göstermektedir. Görüntü üzerinde mavi çizgi ile gösterilen kısım radyologların elle yaptığı işaretlemeleri gösterirken yeşil çizgi ile gösterilen kısım modelin sonucunu göstermektedir.


Şekil 4.5’de ise iskemik veya hemorajik şeklinde inme türüne bakılmaksızın MultiResUNet ile yapılan bölütleme işleminin hemorajik test görüntüleri üzerindeki sonuçlarını göstermektedir.



Şekil 4.3. Soldaki görüntü validasyon görüntüsü, ortadaki görüntü maske görüntüsü, sağdaki görüntü model çıktısı




Şekil 4.4. İskemik test görüntülerinde kesin doğru ve modelin verdiği sonuç.




Şekil 4.5. Hemorajik test görüntülerinde kesin doğru ve modelin verdiği sonuç.

Bölütlenme sonrası elde edilen bölütlenmiş görüntünün hangi inme türüne ait olduğunu tespit etmek için bölütlenmiş görüntüler sınıflandırılmıştır.




a) Eğitim başarı grafiği



b) Eğitim kayıp grafiği

Şekil 4.6. Bölütleme sonrası görüntülerde inme türünü iskemik ve hemorajik olarak belirleyen sınıflandırma işlemine ait eğitim grafikleri

İskemik inme ve hemorajik inme olarak sınıflandırma işleminin eğitimi için 3963 adet iskemik inme görüntüsü ve 3720 adet hemorajik inme görüntüsü ConvNeXt_Tiny modelinde girdi olarak kullanılmıştır. Eğitim başarısı 0,94 olmuştur. Şekil 4.6’da eğitim başarı ve kayıp grafikleri gösterilmektedir.



Şekil 4.7. İskemik ve hemorajik inme sınıflandırma test görüntülerin karışıklık matrisi


Çizelge 4.4. Bölütleme sonrası inme türü sınıflandırma test sonuçları

	Kesinlik (Precision)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	F1-Skor	Doğruluk (Accuracy)
İskemik	0,99	1,00	1,00	1,00	1,00
Hemorajik	1,00	1,00	0,99	1,00	


Test için 382 adet iskemik ve 416 adet hemorajik inme görüntüsü kullanılmıştır. Test görüntülerinden elde edilen model çıktılarına ait karışıklık matrisi Şekil 4.7’de, kesinlik (precision), duyarlılık (sensitivity), f1-score ve doğruluk (accuracy) sonuçları ise Çizelge 4.4’te gösterilmiştir.

4.2. Senaryo 2

Bölüm 3.2’deki veri setinde bulunan görüntüler inme yok, iskemik inme ve hemorajik inme şeklinde sınıflandırma amacıyla bölüm 3.3’teki ön işlemler uygulanarak hazır hale getirilmiştir. 3405 adet inme yok, 3442 adet iskemik inme ve 3442 adet hemorajik inme içeren görüntü ConvNeXt_Tiny modelinin eğitimi için kullanılmıştır. Elde edilen eğitim başarısı 0,96 olmuştur. Şekil 4.8’de eğitim işlemine ait başarı ve kayıp değer grafikleri verilmiştir.




a) Eğitim başarı grafiği



b) Eğitim kayıp grafiği

Şekil 4.8. İnme yok, iskemik ve hemorajik inme sınıflandırması eğitim grafikleri

Eğitim başarısını ölçmek için 462 adet inme yok, 382 adet iskemik ve 416 adet hemorajik inme görüntüleri kullanılmıştır. Şekil 4.9 ve Çizelge 4.5’de inme yok, iskemik inme ve hemorajik inme başarı sonuçları gösterilmiştir.



Şekil 4.9. İnme yok, iskemik inme ve hemorajik inme karışıklık matrisi

Çizelge 4.5. İnme yok, iskemik ve hemorajik inme sınıflandırma başarı sonuçları

	Kesinlik (Precision)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	F1-Skor	Doğruluk (Accuracy)
İnme yok	0,98	0,96	0,98	0,97	0,97
İskemik	0,95	0,97	0,99	0,96	
Hemorajik	0,99	1,00	1,00	0,99	


Sınıflandırma sonrasında görüntülerin hangi bölgesinde inme olduğu ve inmenin ne kadar yayıldığını görmek için inmenin türüne göre görüntü ayrı bölütleme modellerinde girdi olarak kullanılmıştır. Bu amaçla iskemik inme ve hemorajik inme için iskemik bölütleme ve hemorajik bölütleme modelleri oluşturulmuştur. İskemik inme türünün bölütlenmesi için elde edilen eğitim başarısı 0,80'dir. Hemorajik inme türünün bölütlenmesi için elde edilen eğitim başarısı ise 0,84 dür.

İskemik inme bölütleme başarısını ölçmek için 382 adet, hemorajik bölütleme başarısını ölçmek için ise 416 adet test görüntüsü kullanılmıştır ve elde edilen başarı değerleri Çizelge 4.6'da gösterilmiştir.


Çizelge 4.6. İskemik ve hemorajik modellerin bölütleme başarı sonucu

	Jaccard	Dice
İskemik	0,65	0,78
Hemorajik	0,67	0,79

Şekil 4.10'da iskemik bölütleme modelinin doğrulama (validasyon) görüntüleri üzerindeki sonucu gösterilmektedir. Soldaki görüntü validasyon görüntüsünü gösterirken, ortadaki görüntü radyologların belirlediği gerçek maskeyi göstermektedir. Sağdaki görüntü ise bu çalışmada geliştirilen iskemik bölütleme modelinin çıktısını göstermektedir.




Şekil 4.10. İskemik modelin validasyon görüntüleri üzerindeki sonucu



Şekil 4.10. (devam) İskemik modelin validasyon görüntüleri üzerindeki sonucu

Şekil 4.11 iskemik inme test görüntülerinin geliştirilen iskemik bölütleme modeli üzerindeki başarısını göstermektedir. Görüntü üzerinde mavi ile çizilmiş kısım radyologların elle işaretlediği iskemik inme bölgesini gösterirken yeşil ile çizilen kısımlar çalışmadaki modelin bölütleme sonucunu göstermektedir.




Şekil 4.11. İskemik modelin iskemik test görüntüleri üzerindeki çıktıları


Şekil 4.12’de hemorajik bölütleme modelinin doğrulama (validasyon) görüntüleri üzerindeki sonucu gösterilmektedir. Soldaki görüntü validasyon görüntüsünü gösterirken,

ortadaki görüntü radyologların belirlediği gerçek maskeyi göstermektedir. Sağdaki görüntü ise bu çalışmada geliştirilen iskemik bölütleme modelinin çıktısını göstermektedir.


Şekil 4.13 de ise hemorajik bölütleme modelinin hemorajik inme test görüntüleri üzerindeki başarısını göstermektedir. Görüntü üzerinde mavi ile çizilmiş kısım radyologların elle işaretlediği iskemik inme bölgesini gösterirken yeşil ile çizilen kısımlar çalışmadaki modelin bölütleme sonucunu göstermektedir.



Şekil 4.12. Hemorajik modelin validasyon görüntüleri üzerindeki sonucu



Şekil 4.12. (devam) Hemorajik modelin validasyon görüntüleri üzerindeki sonucu



Şekil 4.13. Hemorajik test görüntülerin hemorajik model üzerindeki çıktıları

Yapılan çalışma ile beyin BT görüntülerinde inme sınıflandırması ve bölütleme amaçları için ayrı ayrı çıkarım yapılmıştır. Sınıflandırmada dikkat çeken durum şudur; eğer bütün görüntü üzerinden değil sadece inme bölgesini gösteren bölge girdi olarak kullanılırsa

sınıflandırma başarısı daha yüksek olmaktadır. Bölütleme için de inme sınıfları için ayrı eğitilmiş bölütleme modeli kullanıldığında bölütleme başarımı daha yüksek olmaktadır. Yapılan çalışmada senaryo 1 ile iskemik inme test görüntüleri için elde edilen inme bölütleme Dice skoru 0,58 iken senaryo 2 ile aynı iskemik test görüntülerinden elde edilen iskemik inme bölütleme Dice skoru 0,78 olmuştur.

Bu çalışmada bulunan sonuçlar aynı veri setini kullanan Teknofest yarışmasında dereceye girerek başarı elde edilen çalışmalar ile karşılaştırılmıştır. Çizelge 4.7. inme var ve inme yok sınıflandırması için başarıları gösterirken Çizelge 4.8. bölütleme Jaccard başarı değerleri karşılaştırmasını göstermektedir. Çizelge 4.8 de Göksenin-AI farklı veriseti kullanarak o verilerini testte de kullanarak bu başarıyı elde etmiştir. Aprİkod ve AI Knight ise test veri sonuçları değil eğitim sonuçlarını paylaşmıştır.

Çizelge 4.7. İnme var ve inme yok sınıflandırması

	Kullanılan Model	Test Başarı Sonucu
AI-DEO	ResNeXt50_32x4d	0,88
Göksenin-AI	DenseNet201	0,98
Aprİkod	VGG-16	0,94
AI Knight	DenseNet121	0,94
brAInstorm	U-Net	0,87
Bu Çalışma	ConvNeXt_Tiny	0,98

Çizelge 4.8. İnme bölütleme başarısı

	Kullanılan Model	Jaccard	
		İskemik	Hemorajik
AI-DEO	U-Net	0,65	0,65
Göksenin-AI	U-Net+ InceptionResNetV2	0,76	0,63
Aprİkod	U-Net	0,60	0,60
AI Knight	U-Net	0,54	0,54
brAInstorm	U-Net	0,50	0,50
Bu Çalışma	MultiResUNet	0,67	0,65

Çizelge 4.7. incelendiğinde kullandığımız modelin yarışmada derece elde eden takımların sonuçlarından daha iyi sonuç verdiği görülebilir. Bölütleme başarısı olarak da bu çalışmada kullanılan senaryo 2'nin yarışmada derece elde eden takımlarla benzer bir performans elde ederek başarılı olduğu değerlendirilmiştir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada beyin BT görüntülerinde inme konusunda hem sınıflandırma hem de bölütleme işlemleri yapılmıştır. Sınıflandırmada 4 farklı model kullanılarak inme var ve inme yok sınıflandırmasının başarıları ölçülmüş, aynı zamanda modellerin tespit hızları da hesaplanmıştır. Kullanılan modeller ConvNeXt_Tiny, ResNet50d, EfficienNet_b0 ve ResNeXt101_32x8d modellerdir. Başarı skorları sırasıyla %98, %96, %95 ve %90 ve bir görüntü üzerindeki hızları sırasıyla 0,055, 0,076, 0,047 ve 0,213 sn'dir. Model performansları incelendiğinde ConvNeXt_Tiny modelinin hem başarı da hem de hız konusunda daha yüksek performans gösterdiği görülmüştür. Bu yüzden çalışmadaki bütün sınıflandırmalarda ConvNeXt_Tiny kullanılmıştır. Bölütleme çalışmasında da medikal görüntüler üzerinde başarılı sonuçlar veren MultiResUNet modeli kullanılmıştır.

Çalışmada iki yöntem izlenilmiştir. Birinci yöntemde inme tespiti konusunda inme var ve inme yok olarak iki sınıflı sınıflandırma yapılmıştır. Bu çalışma sonucunda test görüntülerinden %98 başarı elde edilmiştir. Daha sonra inme tespit edilen görüntüler bölütleme modelinde girdi olarak kullanılmıştır. Burada hem iskemik hem de hemorajik görüntü bölütleme başarıları ayrı ayrı ölçülmüştür. İskemik test görüntülerinde %59, hemorajik test görüntülerde %67 Dice başarısı elde edilmiştir. Daha sonra bölütlenen bölgelerdeki inme türünü tespit edilmesi için yapılan sınıflandırmada %100 başarı elde edilmiştir.

Çalışmadaki ikinci yöntemde ise ilk olarak inme yok, iskemik inme ve hemorajik inme olarak üç sınıflı sınıflandırma işlemi yapılmıştır. Sınıflandırıcıdan elde edilen başarı %97'dir. Daha sonra bölütleme yapılması için iskemik inme görüntüleri için bir model ve hemorajik inme görüntüleri için de ayrı bir model kullanılmıştır. Burada iskemik inme test görüntülerinden elde edilen Dice bölütleme başarısı %78 iken hemorajik inme test görüntülerinden elde edilen bölütleme başarısı %79 olmuştur.

Bu çalışmanın amacı doktorlara ikinci bir göz olarak BT görüntülerinde hangi bölgede ve büyüklükte inme yayılımı olduğu ve hangi tür inme olduğu bilgisini vermektir. İnme durumunda tedavi için hızlı karar vermek çok önemli olduğu için gözden kaçan durumların tespiti veya tedavi sürecini hızlandırmaya katkı sağlamak amacıyla bu

alışmanın faydalı olacağı değeriendirilmektedir. Burada amaç hastaların daha az hasarla hastalığı atlatmalarıdır.

Gelecek alışmalarda sınıflama ve bölütleme işlemleri inmenin beyinde etkilediğı alan dikkate alınarak yapılabilir. Çünkü daha küçük bir sızmaya neden olmuş küçük boyutlu inmelerin bulunduğu görüntülerin başarıyı düşürdüğü görülmüştür. Bunun yanında Teknofest yarışmasında sağlanan veriler ile birlikte farklı veri setleri de alışmaya eklenerek alışmada önerilen senaryo 1 ve senaryo 2'nin tekrarlanması durumunda başarının daha da artacağı ön görülmektedir.

KAYNAKLAR

1. Karabudak, R. (2014). İnme. *Türk Nöroloji Derneği 2014 Beyin Yılı Aktiviteleri Raporu*. Türkiye. 1-6
2. Şahan, M., Satar, S., Koc, A. F., ve Sebe, A. (2010). İskemik İnme ve Akut Faz Reaktanları. *Arşiv Kaynak Tarama Dergisi*, 19(2), 85–140.
3. Sacco, R. L., Kasner, S. E., Broderick, J. P., Caplan, L. R., Connors, J. J., Culebras, A., Elkind, M. S. V., George, M. G., Hamdan, A. D., Higashida, R. T., Hoh, B. L., Janis, L. S., Kase, C. S., Kleindorfer, D. O., Lee, J. M., Moseley, M. E., Peterson, E. D., Turan, T. N., Valderrama, A. L., and Vinters, H. V. (2013). An updated definition of stroke for the 21st century: A statement for healthcare professionals from the American heart association/American stroke association. *Stroke*, 44(7), 2064–2089.
4. Çağlayan, T. (2016). *Acil Serviste Hemorajik ve İskemik Serebrovasküler Hastalık Tanısı Alan Hastalarda Kan Laktat Düzeyinin Prognoz Üzerine Etkisi*, Tıpta Uzmanlık Tezi, Eskişehir Osmangazi Üniversitesi Acil Tıp Ana Bilim Dalı, Eskişehir, 30-55.
5. Mackey, J., Mensah, G., Mendis, S., and Greeland, K. (2004). *The atlas of heart disease and stroke*. (1. Baskı). Geneva: World Heath Organization, 37.
6. İnternet: European Stroke Organization, (2018). Avrupa İnme Faaliyeti Planı 2018-2020. URL: <https://www.safestroke.eu/wp-content/uploads/2019/09/SAP-Turkish-s.pdf>, Son Erişim Tarihi: 16.07.2023
7. Tülek, Z., Memiş, S. (2007). İnme Bakımında 2015 Yılı Hedefleri: Avrupa İnme Stratejileri. *Türk Serebrovasküler Hastalıklar Dergisi*, 13(3), 67-73
8. Özen O. H., Çevik, Y., ve Emektar, E. (2018). Evaluation of Radiological Imaging Findings and Affecting Factors in Patients with Acute Ischemic Stroke. *Ankara Medical Journal*, 18(4), 492-9.
9. Doğanay, T. (2022). *Beyin Tümör Tespiti İçin Derin Öğrenme Temelli Bilgisayar Destekli Tanı Sistemi*, Yüksek Lisans Tezi, Gazi Üniversitesi Sağlık Bilişim Ana Bilim Dalı, Ankara, 25-80.
10. İnternet: Bakas, S., Reyes, M., Jakab, A., Bauer, S., Rempfler, M., Crimi, A., Shinohara, R. T., Berger, C., Ha, S. M., Rozycki, M., Prastawa, M., Alberts, E., Lipkova, J., Freymann, J., Kirby, J., Bilello, M., Fathallah-Shaykh, H., Wiest, R., Kirschke, J., ... Menze, B. (April, 2018). Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge. URL: <https://arxiv.org/pdf/1811.02629.pdf> , Son Erişim Tarihi: 17.07.2023.
11. Isensee, F., Kickingeder, P., Wick, W., Bendszus, M., and Maier-Hein, K. H. (2019). No new-net. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 234–244.
12. Weng, W., and Zhu, X. (2021). INet: Convolutional Networks for Biomedical Image Segmentation. *IEEE Access*, 9, 16591–16603.

13. Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., and Liang, J. (2020). UNet++: Redesigning Skip Connections to Exploit Multiscale Features in Image Segmentation. *IEEE Transactions on Medical Imaging*, 39(6), 1856–1867.
14. Xu, Y., Holanda, G., Souza, L. F. D. F., Silva, H., Gomes, A., Silva, I., Ferreira, M., Jia, C., Han, T., De Albuquerque, V. H. C., and Filho, P. P. R. (2021). Deep Learning-Enhanced Internet of Medical Things to Analyze Brain CT Scans of Hemorrhagic Stroke Patients: A New Approach. *IEEE Sensors Journal*, 21(22), 24941–24951.
15. Abramova, V., Clèrigues, A., Quiles, A., Figueredo, D. G., Silva, Y., Pedraza, S., Oliver, A., and Lladó, X. (2021). Hemorrhagic stroke lesion segmentation using a 3D U-Net with squeeze-and-excitation blocks. *Computerized Medical Imaging and Graphics*, 90.
16. Raghavendra, U., Pham, T. H., Gudigar, A., Vidhya, V., Rao, B. N., Sabut, S., Wei, J. K. E., Ciaccio, E. J., and Acharya, U. R. (2021). Novel and accurate non-linear index for the automated detection of haemorrhagic brain stroke using CT images. *Complex and Intelligent Systems*, 7(2), 929–940.
17. Gautam, A., and Raman, B. (2021). Towards effective classification of brain hemorrhagic and ischemic stroke using CNN. *Biomedical Signal Processing and Control*, 63, 102178.
18. Badriyah, T., Sakinah, N., Syarif, I., and Syarif, D. R. (2020,12-13 June). *Machine Learning Algorithm for Stroke Disease Classification*. 2nd International Conference on Electrical, Communication and Computer Engineering, İstanbul, 5.
19. Neethi, A. S., Niyas, S., Kannath, S. K., Mathew, J., Anzar, A. M., and Rajan, J. (2022). Stroke classification from computed tomography scans using 3D convolutional neural network. *Biomedical Signal Processing and Control*, 76, 103720.
20. Soltanpour, M., Greiner, R., Boulanger, P., and Buck, B. (2019, 28-30 October). *Ischemic stroke lesion prediction in CT perfusion scans using multiple parallel u-nets following by a pixel-level classifier*. Proceedings - 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering, Athens, 7.
21. de Vries, L., Emmer, B. J., Majoie, C. B. L. M., Marquering, H. A., and Gavves, E. (2023). PerfU-Net: Baseline infarct estimation from CT perfusion source data for acute ischemic stroke. *Medical Image Analysis*, 85, 102749.
22. Ma, Y., Ren, F., Li, W., Yu, N., Zhang, D., Li, Y., and Ke, M. (2023). IHA-Net: An automatic segmentation framework for computer-tomography of tiny intracerebral hemorrhage based on improved attention U-net. *Biomedical Signal Processing and Control*, 80(1), 104320.
23. Han, T., Nunes, V. X., De Freitas Souza, L. F., Marques, A. G., Silva, I. C. L., Junior, M. A. A. F., Sun, J., and Filho, P. P. R. (2020). Internet of medical things - Based on deep learning techniques for segmentation of lung and stroke regions in CT Scans. *IEEE Access*, 8, 71117–71135.

24. İnternet: AI-DEO. (2021). Teknofest Havacılık, Uzay ve Teknoloji Festivali Sağlıkta Yapay Zeka Yarışması Kritik Tasarım ve Ön Bulgu Raporu. URL: <https://cdn.t3kys.com/media/upload/userFormUpload/9kkkFqHezfSYRFe2dli7WnfhRKvq6uD.pdf>, Son Erişim Tarihi: 16.07.2023
25. İnternet: Göksenin-AI. (2021). Teknofest Havacılık, Uzay ve Teknoloji Festivali Sağlıkta Yapay Zeka Yarışması Kritik Tasarım ve Ön Bulgu Raporu. URL: <https://cdn.t3kys.com/media/upload/userFormUpload/y3ulriN6KeT5kX8xHmV1E1dYyiFbZJA2.pdf>, Son Erişim Tarihi: 16.07.2023
26. İnternet: Brain CT Images with Intracranial Hemorrhage Masks. URL: <https://www.kaggle.com/datasets/vbookshelf/computed-tomography-ct-images>, Son Erişim Tarihi: 04.12.2019
27. İnternet: Aprİkod. (2021). Teknofest Havacılık, Uzay ve Teknoloji Festivali Sağlıkta Yapay Zeka Yarışması Kritik Tasarım ve Ön Bulgu Raporu. URL: <https://cdn.t3kys.com/media/upload/userFormUpload/9TNq6vPE1USRfVR6Kbn45jbNgT04Q5RC.pdf>, Son Erişim Tarihi: 16.07.2023
28. İnternet: AI Knight. (2021). Teknofest Havacılık, Uzay ve Teknoloji Festivali Sağlıkta Yapay Zeka Yarışması Kritik Tasarım ve Ön Bulgu Raporu. URL: <https://cdn.t3kys.com/media/upload/userFormUpload/U7xyivdD4Ck0HzuHoNlIFuAT0TuuQOav.pdf>, Son Erişim Tarihi: 16.07.2023
29. İnternet: brAInstorm. (2021). Teknofest Havacılık, Uzay ve Teknoloji Festivali Sağlıkta Yapay Zeka Yarışması Kritik Tasarım ve Ön Bulgu Raporu. URL: <https://cdn.t3kys.com/media/upload/userFormUpload/pURwcfNBmrR5NKtLwwLfpYmH52v1kVyG.pdf>, Son Erişim Tarihi: 16.07.2023
30. İnternet: NIH. (2022). Computed Tomography. URL: <https://www.nibib.nih.gov/science-education/science-topics/computed-tomography-ct> Son Erişim Tarihi: 29.07.2023
31. İnternet: Computed Tomography (CT). (2023). URL: <https://app.lecturio.com/#!/article/2851?return=%23%2Fwelcome%3Ffv%3D1>, Son Erişim Tarihi: 29.03.2023
32. Tepper, S. J. (2008). Computed tomography - An increasing source of radiation exposure: Commentary. *Headache*, 48(4), 657.
33. İnternet: Teknofest (2023). URL: <https://teknofest.org/tr/>, Son Erişim Tarihi: 18.04.2023
34. İnternet: İnme Veri Seti (2021). URL: <https://acikveri.saglik.gov.tr/Home/DataSets?categoryId=10>, Son Erişim Tarihi: 03.04.2023
35. İnternet: Pydicom. (2023). URL: <https://pydicom.github.io/>, Son Erişim Tarihi: 22.01.2023

36. Ural A. B. (2022). Computer Aided Deep Learning Based Assessment of Stroke From Brain Radiological CT Images. *European Journal of Science and Technology*, 34, 42–52.
37. Hounsfield, N. G. (1980). Computed medical imaging. *Journal of Computer Assisted Tomography*, 4(5), 665–674
38. Raid, A. M., Khedr, W. M., El-dosuky, M. A., and Aoud, M. (2014). Image Restoration Based on Morphological Operations. *International Journal of Computer Science, Engineering and Information Technology*, 4(3), 9–21.
39. Sreedhar, K., and Panlal, B. (2012). Enhancement Of Images Using Morphological Transformations. *International Journal of Computer Science & Information Technology (IJCSIT)*. 4(1), 33–50.
40. Adeyemo, A., Wimmer, H., and Powell, L. (2020). Effects of Normalization Techniques on Logistic Regression in Data Science. *Investigation and Prevention of Financial Crime*, 12(2), 89–104.
41. Yüce, H., and Özkan, A. O. (2021). Normalizasyon Yöntemlerinin Biyomedikal Verilerde Sınıflandırma Performansına Etkisi. *European Journal of Science and Technology*, 2021(30), 35–43.
42. Öztürk, N., and Öztürk, S. (2022). Bölütleme Tabanlı Yeni Görüntü İyileştirme Yöntemi. *European Journal of Science and Technology*, 32, 675–681.
43. Musa, P., Rafi, F. Al, and Lamsani, M. (2018, 17-18 October). *A review: Contrast-limited adaptive histogram equalization (CLAHE) methods to help the application of face recognition*. Proceedings of the 3rd International Conference on Informatics and Computing, Delhi, 6.
44. Şengöz, N., Yiğit, T., Özmen, Ö., and Isık, A. H. (2022). Importance of Preprocessing in Histopathology Image Classification Using Deep Convolutional Neural Network. *Advances in Artificial Intelligence Research*, 2(1), 1–6.
45. Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., and Xie, S. (2022, 18-24 June). *A ConvNet for the 2020s*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Juan, 15.
46. Jiang, L., Yuan, B., Ma, W., and Wang, Y. (2023). JujubeNet: A high-precision lightweight jujube surface defect classification network with an attention mechanism. *Frontiers in Plant Science*, 13(1), 1–16.
47. Ibtehaz, N., and Rahman, M. S. (2020). MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks*, 121, 74–87.
48. İnternet: What is MultiResUNET? (2023) URL: <https://idiotdeveloper.com/what-is-multiresunet/> , Son Erişim Tarihi:15.07.2023

49. İnik, Ö., and Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Journal of Scientific Research*, 6(3), 85–104.
50. İnternet: Introduction to Convolutional Neural Networks Architecture. (2023). URL: <https://www.projectpro.io/article/introduction-to-convolutional-neural-networks-algorithm-architecture/560>, Son Erişim Tarihi:15.07.2023.
51. Ioffe, S., and Szegedy, C. (2015, 6-11 July). *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. 32nd International Conference on Machine Learning, Lille, 11.
52. Nair, V., and Hinton, G. E. (2010, 21-24 June). *Rectified Linear Units Improve Restricted Boltzmann Machines*. Appearing in Proceedings of the 27 th International Conference on Machine Learning, Haifa, 7.
53. Agarap, A. F. (2018). Deep Learning using Rectified Linear Units (ReLU). 1, 2–8.
54. İnternet: Gholamalinezhad, H., and Khosravi, H. (2020). Pooling Methods in Deep Neural Networks, URL: <https://arxiv.org/ftp/arxiv/papers/2009/2009.07485.pdf>, Son Erişim Tarihi:16.07.2023.
55. Zafar, A., Aamir, M., Mohd Naw, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., and Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences (Switzerland)*, 12(17), 1–21.
56. Du, C., Wang, Y., Wang, C., Shi, C., and Xiao, B. (2020). Selective feature connection mechanism: Concatenating multi-layer CNN features with a feature selector. *Pattern Recognition Letters*, 129, 108–114.
57. Basha, S. H. S., Dubey, S. R., Pulabaigari, V., and Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112–119.
58. Gürkan, Ç. (2021). *Endüstri 4.0 ve Dijital Dönüşüm Teknolojileri ile Desteklenen Akıllı Fabrika Yönetim ve Bilişim Sisteminin Geliştirilmesi*. Yüksek Lisans Tezi, İzmir Kâtip Çelebi Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 23-43.
59. İnternet: Ruder, S. (2016). An overview of gradient descent optimization. URL: <https://arxiv.org/pdf/1609.04747.pdf>, Son Erişim Tarihi: 15.07.2023.
60. İnternet: Karışıklı Matrisi (Confusion Matrix). (2021). URL: <https://burhanbilen.medium.com/kar%C4%B1%C5%9F%C4%B1kl%C4%B1k-matrisi-confusion-matrix-990dfc718653>, Son Erişim Tarihi: 24.07.2023
61. İnternet: Vakili, M., Ghamsari, M., and Rezaei, M. (n.d.). (2020). Performance Analysis and Comparison of Machine and Deep Learning Algorithms for IoT Data Classification, URL: <https://arxiv.org/ftp/arxiv/papers/2001/2001.09636.pdf>, Son Erişim Tarihi: 02.08.2023.

62. Prabha, D. S., and Kumar, J. S. (2016). Performance Evaluation of Image Segmentation using Objective Methods. *Indian Journal of Science and Technology*, 9(8), 1–8.



Gazili olmak ayrıcalıktır