

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

**SUBDURAL BEYİN KANAMALARININ DERİN ÖĞRENME
MODELLERİ İLE BÖLÜTLENMESİ VE SINIFLANDIRILMASI**

TUĞRUL HAKAN GENÇTÜRK

KOCAELİ – 2023

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

SUBDURAL BEYİN KANAMALARININ DERİN ÖĞRENME
MODELLERİ İLE BÖLÜTLENMESİ VE
SINIFLANDIRILMASI

TUĞRUL HAKAN GENÇTÜRK

Dr. Öğr. Üyesi Fidan KAYA GÜLAĞIZ

Danışman, Kocaeli Üniv.

.....

Prof. Dr. Sevinç İlhan OMURCA

Jüri Üyesi, Kocaeli Üniv.

.....

Dr. Öğr. Üyesi Ekin EKİNCİ

Jüri Üyesi, Sakarya Uygulamalı Bilimler Üniv.

.....

Tezin Savunulduğu Tarih: 12.06.2023

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmada,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

☒ Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☐ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler tarafından no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

.....

Tuğrul Hakan GENÇTÜRK

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki makale, kitap, tebliğ, lisans, patent gibi çalışmalarda kullanımı bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan **“Lisanüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- ☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
- ☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.
- ☒ Tezim projem ile ilgili gizlilik kararı verilmemiştir.

.....
Tuğrul Hakan GENÇTÜRK

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması, derin öğrenme tekniklerini kullanarak beyin kanamalarının otomatik tespitini, sınıflandırılmasını ve bölütlemesini gerçekleştirecek etkili bir yöntem geliştirmek amacıyla yapılmıştır.

Yüksek Lisans eğitimim süresince desteğini esirgemeyen, tezimin her aşamasında sorunlarımı dinleyerek, görüşleri ile çalışmalarına katkıda bulunan ve yoğun akademik yaşamında değerli zamanını her türlü problemimi çözmeye ayıran tez danışmanım saygı değer hocam Dr. Öğretim Üyesi Fidan KAYA GÜLAĞIZ'a içtenlikle teşekkür ederim.

Tez çalışmam boyunca gösterdiği destek için Doç. Dr. Suhap ŞAHİN'e, tez çalışmama bilgi ve tavsiyeleri ile katkıda bulunan Beyin ve Sinir Cerrahisi Dr. Öğr. Üyesi İsmail KAYA'ya

Maddi ve manevi desteklerini tüm hayatı boyunca esirgemeyen annem Gülcan GENÇTÜRK, babam Bekir GENÇTÜRK ve kardeşim Adalet Nur GENÇTÜRK'e teşekkürü borç bilirim.

Haziran – 2023

Tuğrul Hakan GENÇTÜRK

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ.....	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ	v
TABLolar DİZİNİ.....	vi
SİMGELER VE KISALTMALAR DİZİNİ	vii
ÖZET	viii
ABSTRACT	ix
1. GİRİŞ.....	1
2. KONSEPT VE TERMİNOLOJİ.....	4
2.1. Beyin Kanamalarının Türleri	4
2.2. Medikal Görüntüleme Teknikleri.....	5
2.3. Medikal Görüntüleme Dosya Formatları	6
2.4. Görüntü Bölütlenmesi.....	7
2.5. Görüntü Sınıflandırma	8
3. LİTERATÜR ÖZETİ.....	9
3.1. Beyin Kanamalarının Tespit Edilmesi	9
3.2. Beyin Kanamalarının Bölütlenmesi.....	12
4. MATERYAL VE YÖNTEM.....	15
4.1. Veri Kümeleri.....	15
4.2. Sınıflandırma Teknikleri	17
4.2.1. VGG (Visual Geometry Group)	17
4.2.2. ResNet (Residual Neural Network).....	19
4.2.3. EfficientNet.....	20
4.3. Bölütleme Teknikleri	21
4.3.1. Mask R-CNN	21
4.3.2. Cascade Mask R-CNN.....	22
4.3.3. Mask Scoring R-CNN.....	23
4.3.4. Hybrid Task Cascade	23
4.3.5. YOLACT	24
4.3.6. QueryInst	25
4.3.7. SCNet.....	25
4.4. Önerilen Hibrit Beyin Kanaması Tespit Yöntemi.....	26
4.5. Değerlendirme Ölçütleri	28
5. DENEYSEL ÇALIŞMA.....	31
5.1. Sınıflandırma Sonuçları	32
5.2. Bölütleme Sonuçları	35
5.3. Hibrit Model Sonuçları	37
6. SONUÇLAR VE ÖNERİLER.....	41
KAYNAKLAR	43
KİŞİSEL YAYIN VE ESERLER.....	49
ÖZGEÇMİŞ	50

ŞEKİLLER DİZİNİ

Şekil 2.1.	Örnek beyin kanaması görüntüleri	5
Şekil 4.1.	CQ500 veri kümesinden etiketli örnek taramalar	16
Şekil 4.2.	PhysioNet veri kümesinden etiketli örnek taramalar	16
Şekil 4.3.	VGG-11 ağ mimarisi	18
Şekil 4.4.	ResNet-50 ağ mimarisi	19
Şekil 4.5.	EfficientNet-B0 ağ mimarisi	20
Şekil 4.6.	Mask R-CNN'nin genel mimarisi	22
Şekil 4.7.	Cascade Mask R-CNN genel mimarisi	23
Şekil 4.8.	MS R-CNN genel mimarisi	23
Şekil 4.9.	Hybrid Task Cascade genel mimarisi	24
Şekil 4.10.	YOLACT genel mimarisi	24
Şekil 4.11.	Dinamik maske kafasına sahip QueryInst'e genel bakış.	25
Şekil 4.12.	SCNet genel mimarisi	26
Şekil 4.13.	Önerilen hibrit sistemin genel mimarisi	27
Şekil 5.1.	PhysioNet veri kümesinde sınıflandırma modellerinden elde edilen doğruluk değerleri	33
Şekil 5.2.	PhysioNet veri kümesinde sınıflandırma modellerinden elde edilen f1 skor değerleri	33
Şekil 5.3.	CQ500 veri kümesinde sınıflandırma modellerinden elde edilen doğruluk değerleri	33
Şekil 5.4.	CQ500 veri kümesinde sınıflandırma modellerinden elde edilen f1 skor değerleri	34
Şekil 5.5.	Sadece Sınıflandırıcı Model ile Elde Edilen Sonuçlar	38
Şekil 5.6.	Sadece Sınıflandırıcı Modeller ile Elde Edilen Karmaşıklık Matrisleri	38
Şekil 5.7.	Hibrit Model ile Elde Edilen Sınıflandırma Sonuçları	39
Şekil 5.8.	Hibrit Model ile Elde Edilen Karmaşıklık Matrisleri	40

TABLolar DİZİNİ

Tablo 4.1.	Veri kümelerine genel bakış tablosu.....	17
Tablo 4.2.	VGG ağ mimarisi genel katman tablosu	18
Tablo 4.3.	ResNet ağ mimarisi genel katman tablosu	19
Tablo 4.4.	EfficientNet modellerine ait genel özellik tablosu	21
Tablo 5.1.	PhysioNet veri kümesi sınıflandırma modellerinden elde edilen sınıflandırma sonuçları	34
Tablo 5.2.	CQ500 veri kümesi sınıflandırma modellerinden elde edilen sınıflandırma sonuçları	35
Tablo 5.3.	Bölütleme modellerinin genel mimarisi	36
Tablo 5.4.	Bölütleme modellerinin doğruluk değerleri	36
Tablo 5.5.	Hibrit Yöntemin Literatür ile Karşılaştırılması	40



SİMGELER VE KISALTMALAR DİZİNİ

<i>TP</i>	: Gerçek pozitif değer sayısı
<i>TN</i>	: Gerçek negatif değer sayısı
<i>FP</i>	: Yanlış pozitif değer sayısı
<i>FN</i>	: Yanlış negatif değer sayısı
<i>P</i>	: Kesinlik, gerçek pozitif tahminlerinin toplam pozitif tahminlere oranı
<i>R</i>	: Duyarlılık, gerçek pozitif tahminlerinin toplam gerçek pozitif örnek sayısına oranı
<i>AP</i>	: Hassasiyet ve duyarlılık metriklerinin birleşimi olarak, modelin doğruluk ve kapsamını ölçen metrik

Kısaltmalar

BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağı)
DICOM	: Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)
EDH	: Epidural Hematoma (Epidural Kanama)
FCN	: Fully Convolutional Network (Tamamen Evrişimli Ağ)
FPN	: Feature Pyramid Network (Özellik Piramit Ağı)
HTC	: Hybrid Task Cascade (Karma Görev Kaskadı)
ICH	: Intracerebral Hematoma (İntrakraniyal Kanama)
IoU	: Intersection over Union (Örtüşme Oranı)
IPH	: Intraparenchymal Hemorrhage (İntraparankimal Kanama)
LGBM	: Light Gradient Boosting Machine (Hafif Gradyan Artırma Makinesi)
mAP	: Mean Average Precision (Ortalama Hassasiyet)
MBConv	: Mobile Inverted Bottleneck Convolution (Mobil Ters Çevirilmiş Darboğaz Konvolüsyonu)
MINC	: Medical Imaging NetCDF (Tıbbi Görüntüleme NetCDF)
MRI	: Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
MS R-CNN	: Mask Scoring Bölgesel Tabanlı Evrişimli Sinir Ağı
NIFTI	: Neuroimaging Informatics Technology Initiative (Nörogörüntü Bilgi Teknolojisi Girişimi)
R-CNN	: Region-based Convolutional Neural Network (Bölgesel Tabanlı Evrişimli Sinir Ağı)
ResNet	: Residual Network (Kalıntı Ağı)
ROI	: Region of Interest (İlgi Bölgesi)
RoIPooling	: Region of Interest Pooling (İlgi Bölgesi Havuzlama)
RPN	: Region Proposal Network (Bölge Önerisi Ağı)
RSNA	: Radiological Society of North America (Kuzey Amerika Radyoloji Derneği)
SCNet	: Sample Consistency Network (Örnekleme Tutarlılık Ağı)
SDH	: Subdural Hematoma (Subdural Kanama)
TBI	: Traumatic Brain Injury (Travmatik Beyin Hasarı)
VGG	: Visual Geometry Group (Görsel Geometri Grubu)
YOLACT	: You Only Look At CoefficientTs (Yalnızca Katsayıları Bak)

SUBDURAL BEYİN KANAMALARININ DERİN ÖĞRENME MODELLERİ İLE BÖLÜTLENMESİ VE SINIFLANDIRILMASI

ÖZET

Beyin kanaması, acil müdahale gerektiren ciddi bir durumdur ve erken teşhis hayati önem taşır. Bilgisayarlı tomografi (BT) görüntülemesi, beyin kanamasının tespitinde yaygın olarak kullanılan bir yöntemdir. Bu tez çalışmasında, BT görüntüler kullanılarak beyin kanamasının tespiti için hibrit bir model geliştirilmiştir, model bölütleme ve sınıflandırma aşamalarından oluşmaktadır. İlk aşamada Mask Scoring RCNN modeliyle taramalar "kanamalı" ve "sağlıklı" bölgelere ayrıştırılır. İkinci aşamada ise EfficientNet-B2 modeliyle doğrulama işlemi yapılır ve bölütlenen bölgelerin gerçekten beyin kanaması içerip içermediği belirlenir.

Bu çalışma, subdural hematoma (SDH) kanamalarının bölütlenmesi ve sınıflandırılması çalışmaları için değerli bir veri kümesi sunmaktadır. Literatürdeki güncel modeller ve mimariler üzerinde yapılan karşılaştırmalı çalışmalar, beyin kanamalarının sınıflandırılması ve bölütlenmesi için önemli bir temel oluşturmaktadır. Hibrit modelin performansı, hasta bazlı ve rastgele bölümlerle değerlendirilerek genelleme yeteneği gösterilmiştir. Ayrıca, bu çalışma, iki aşamalı bir yaklaşımı benimseyerek diğer çalışmalardan farklılık göstermektedir. Hibrit modelin, literatürdeki benzer çalışmalara göre daha başarılı bir sınıflandırma performansı sergilediği belirlenmiştir, bu da modelin etkili bir şekilde beyin kanamalarını sınıflandırma yeteneğini ortaya koyar.

Geliştirilen yöntem, doktorlara daha doğru tanısal bilgi ve rehberlik sunarak tedavi sürecinde etkin kararlar almalarına yardımcı olabilir. Bu sayede, hastaların erken teşhis edilmesi ve uygun tedaviye yönlendirilmesi sağlanarak yaşam kalitesi artırılabilir ve olumsuz etkiler minimize edilebilir.

Anahtar Kelimeler: Beyin Kanaması, Bilgisayarlı Tomografi, Bölütleme, Sınıflandırma.

SEGMENTATION AND CLASSIFICATION OF SUBDURAL BRAIN HEMORRHAGES WITH DEEP LEARNING MODELS

ABSTRACT

Brain hemorrhage is a serious condition that requires immediate intervention, and early diagnosis is crucial. Computed tomography (CT) imaging is a widely used method for detecting brain hemorrhage. In this thesis, a hybrid model is developed for the detection of brain hemorrhage, consisting of segmentation and classification stages. In the first stage, scans are segmented into "hemorrhagic" and "healthy" regions using the Mask Scoring RCNN model. In the second stage, the EfficientNet-B2 model is used for verification, determining whether the segmented regions indeed contain brain hemorrhage.

This study provides a valuable dataset for the segmentation and classification of subdural hematomas (SDH), contributing to the research in this field. Comparative studies conducted on current models and architectures in the literature establish an important foundation for the classification and segmentation of brain hemorrhages. The performance of the hybrid model is evaluated using patient-based and random partitioning techniques, demonstrating its generalization ability. Furthermore, this study adopts a two-stage approach, distinguishing itself from other works. It is observed that the hybrid model outperforms similar studies in terms of classification performance, highlighting its effective ability to classify brain hemorrhages.

The developed method can assist doctors in making more accurate diagnostic decisions and providing guidance in the treatment process. Consequently, early detection of patients and appropriate referral for treatment can improve quality of life and minimize adverse effects.

Keywords: Brain Hemorrhage, Computed Tomography, Segmentation, Classification.

1. GİRİŞ

Bilgisayarlı tomografi (BT) keşfedilmesinden bu yana, tıbbi görüntüleme teknikleri arasında vazgeçilmez bir yöntem olmuştur (Richmond, 2004) ve acil durumlarda kullanılan en önemli görüntüleme araçlarından bir tanesidir (Kuno ve diğ., 2017). Manyetik rezonans görüntüleme (MRI) ile kıyaslandığında, uzun süreli hareketsizlik gereksinimi olmaması, özellikle entübe ve klostrofobik hastalarda kullanışlı olması ve metal vücut implantları olan hastalardan elde edilebilir olması gibi avantajları nedeniyle BT'nin alternatifi yoktur (Hori ve diğ., 1998). Ayrıca, BT'nin mobil organlardan saniyeler içinde elde edilebilir olması, acil ve uyumsuz hastalar açısından önemlidir. (Kaya ve diğ., 2023).

Ülkemizde neredeyse her hastanede BT cihazı bulunmaktadır (URL-1). Tomografi teknolojisinin bu kadar yaygınlaşması ve kolay erişilebilir hale gelmesi, yeni zorlukları da beraberinde getirmiştir. Hastaların hızlı bir şekilde tedaviye yönlendirilebilmesinde, BT görüntülerinin doğru ve hızlı bir şekilde yorumlanması kritik öneme sahiptir. Günümüzde, BT görüntülerinin incelenip raporlanması radyoloji uzmanları tarafından gerçekleştirilmektedir. Ancak radyoloji uzmanının hemen bulunmadığı durumlarda tanı koyulması dolayısıyla da tedavi sürecinde gecikmeler yaşanmaktadır. Özellikle uzman doktorların hizmet vermediği acil servisler gibi alanlarda pratisyen hekimler zaman zaman tüm vücut tomografilerini yorumlamak zorunda kalabilmektedir (Kaya ve diğ., 2023). Yukarıda bahsedilen durumlar göz önünde bulundurulduğunda BT görüntülerinin yorumlanması konusunda yapay zeka temelli destek yazılımlarına olan ihtiyaç anlaşılmaktadır.

Yapay zeka, temelde makinelerin, insan zekası tarafından gerçekleştirilen görevleri taklit edebilme yeteneğini ifade eder (Kurzweil ve diğ., 1990). Yapay zekâ çatısı altında, makine öğrenmesi ve derin öğrenme gibi iki önemli alt dal bulunmaktadır ve her birinin gün geçtikçe popülaritesi artmaktadır. Makine öğrenmesi, makinelerin verilerden anlamlı ve kullanışlı bilgiler çıkarmasına odaklanırken, derin öğrenme, bu süreci daha da derinleştirerek, karmaşık veri yapılarından bilgi çıkarılmasını sağlar. Makine öğrenmesi ve derin öğrenme arasındaki temel farklılıklar, öğrenme süreçlerinin hızı ve veri işleme yöntemleridir. Makine öğrenme teknikleri, genellikle hızlı bir öğrenme sürecine sahipken, belirli özellikleri çıkarabilmek için daha fazla ön işleme ihtiyacı duyarlar. Öte yandan,

derin öğrenme teknikleri, genellikle daha uzun eğitim süreleri gerektirse de özellik çıkarma sürecini otomatikleştirirler, yani karmaşık veri yapılarından otomatik olarak özellikler çıkarabilirler. Derin öğrenme teknikleri, büyük veri kümelerinde daha başarılıdır ve aynı zamanda sayısal olmayan veya ses ve görüntü gibi kategorik olmayan veri türleriyle de çalışabilirler.

Bu tez çalışmasında, BT görüntülerinin yorumlanmasında mevcut olan zorlukları, yapay zekâ yöntemleriyle gidermeye yardımcı olacak bir yaklaşım önerilmiştir. Çalışma kapsamında, beyin kanamalarının bir alt türü olan Subdural kanamalar (SDH) için acil durumlarda doktorlara hızlı bir şekilde uyarıda bulunabilecek iki seviyeli bir model geliştirilmiştir. Bu model, hem bölütleme (yani kanamalı bölgenin belirlenmesi ve maske oluşturulması) hem de ikili sınıflandırma (yani görüntünün kanamalı veya sağlıklı olduğunun belirlenmesi) işlemlerini gerçekleştirecek şekilde tasarlanmıştır.

Önerilen model bölütleme aşamasında, derin öğrenme temelli bir teknik olan Mask Scoring Bölgesel Tabanlı Evrişimli Sinir Ağı (MS R-CNN)'i kullanmaktadır. İkili sınıflandırma aşamasında ise, EfficientNet-B2 mimarisini kullanmaktadır. MS R-CNN yöntemi, tomografi görüntüsündeki potansiyel kanama bölgelerini belirlemektedir. EfficientNet-B2 modeli ise bölütleme modeli tarafından belirlenen bölgeler üzerinden, bu bölgelerin gerçekten kanama içerip içermediğini tespit etmektedir. Böylece önerilen yöntem iki seviyeli bir doğrulama yaklaşımı sunmaktadır.

Yapılan ulusal ve uluslararası literatür araştırmalarında BT görüntüler üzerinden SDH bölütlenmesi ve sınıflandırması yapan yöntemler incelendiğinde bölütlenen kanama bölgesi üzerinden sınıflandırma yaparak iki seviyeli doğrulama sunan bir çalışma görülmemiştir. Bu nedenle, bu tez çalışmasının oldukça özgün bir değere sahip olduğu ve önerilen iki seviyeli yöntemin hem SDH hem de diğer kanama türlerinin tespiti konusunda yeni bir yaklaşım sunması açısından literatüre önemli katkılar sağlayacağı düşünülmektedir.

Tez çalışmasının ikinci bölümünde tez içerisinde kullanılan bazı terimler / terminolojiler hakkında bilgi verilecektir. Üçüncü bölümde beyin kanamalarının bölütlenmesi ve sınıflandırılması konularında yapılan güncel çalışmaların bir özeti sunulacaktır. Dördüncü bölümde önerilen yöntemin belirlenmesi aşamasında kullanılan

algoritmalarından ve önerilen iki seviyeli modelden bahsedilecektir. Deneysel çalışma bölümü olan beşinci bölümde elde edilen sonuçlar kapsamlı olarak verilecektir. Altıncı bölümde, elde edilen sonuçlar genel hatlarıyla literatürdeki benzer çalışmalarla karşılaştırılarak, çalışmanın bilime ve günümüz teknolojisine sağlayabileceği katkıları tartışılacaktır. Ayrıca ileriye dönük yapılabilecek çalışmalar için önerilerde bulunulacaktır.




2. KONSEPT VE TERMİNOLOJİ

Bu bölümde, tıbbi görüntü işleme ve analiz alanında kullanılan kritik kavramlar ve terminolojilere odaklanılmıştır. İlk olarak, farklı beyin kanama türleri ele alınarak, tez konusuyla ilgili temel bilgiler sunulmuştur. Ardından, medikal görüntüleme teknikleri ve dijital görüntülerin temel özelliklerinden bahsedilmiştir. Son olarak, görüntü sınıflandırma ve bölütleme yöntemlerinin önemine ve bu alandaki temel kavramlara değinilmiştir. Bu bölüm, tezin ilerleyen kısımlarında ele alınacak yöntemler ve teknikler için bir temel oluşturmaktadır.

2.1. Beyin Kanamalarının Türleri

Beyin kanamaları, farklı nedenlerle beyin dokusunda veya çevresinde meydana gelen kan birikmeleridir. Beyin kanamalarının doğru tespiti ve sınıflandırılması, uygun tedavi yaklaşımlarının belirlenmesinde ve hastaların yaşam kalitesinin korunmasında kritik öneme sahiptir. Ayrıca, bu bilgi, tıbbi görüntü işleme ve analiz çalışmalarında kullanılacak yöntemlerin ve algoritmaların geliştirilmesine de katkıda bulunmaktadır. Beyin kanamaları özelliklerine göre 5 farklı gruba ayrılır. Bu gruplar epidural kanamalar, subdural kanamalar, subaraknoid kanamalar, intraparaknoidal kanamalar ve intraventriküler kanamalar olarak isimlendirilir. Epidural kanamalar başa alınan travmatik darbeler sonucu ortaya çıkar ve genellikle atardamar veya toplardamar kaynaklıdır (Tenny ve Thorell, 2023). Atardamar kökenli epidural kanamalar, başın özellikle temporal bölgesine gelen darbelerle ilişkilidir ve orta meningeal arterin zarar görmesi sonucu oluşur. Epidural kanamalar, baş yaralanması olan hastaların yaklaşık %2'sinde bulunur ve ölümcül baş yaralanmalarının %5 ila %15'ini oluşturur. Subdural kanama, beyin ve kafatası arasındaki damarların yırtılmasıyla kanın subdural alana sızması sonucu meydana gelir. Bu durum, çoğunlukla travmatik baş darbeleri sonucu oluşsa da baş yaralanmalarında veya gelişigüzel olarak da ortaya çıkabilir. Önemli baş yaralanması geçiren hastaların %5 ila %25'inde subdural kanama görülme olasılığı bulunmaktadır. Yılda 100.000 kişi başına 1 ila 5 subdural kanama vakası meydana gelmekte ve erkeklerde kadınlara göre iki kat daha sık rastlanmaktadır (Tenny ve Thorell, 2023).

Subaraknoid kanama, kanın beyin zarlarının arasındaki subaraknoid boşluğa sızması durumudur. Tüm inme vakalarının yaklaşık %5'ini oluşturur. 35 yaşından büyüklerde, her 100.000 kişiden 2 ila 25'i arasında subaraknoid kanama meydana gelmektedir. Yaş ilerledikçe bu vakaların sayısı kademeli olarak artar ve kadınlarda erkeklere kıyasla biraz daha yaygın görülür. (Tenny ve Thorell, 2023). Intraparenkimal kanama, beyin dokusu içerisinde meydana gelen kanamaları tanımlar. Bu tür kanamalar, çeşitli nedenlerle ortaya çıkabilir. Bunlar arasında yüksek tansiyon, damar anormallikleri, beyin damarlarında protein birikimi, anevrizma yırtılması, beyin tümörleri, pıhtılaşma sorunları, enfeksiyonlar, damar iltihabı ve başa alınan travmalar yer alır. Intraparenkimal kanamalar, farklı faktörlerin etkisiyle oluştuğu için tedavi ve yönetimi de karmaşıktır. Bu durum, özellikle yaşlı bireylerde ve altta yatan sağlık sorunları olan kişilerde daha yaygın ve risklidir (Tenny ve Thorell, 2023). İntraventriküler kanama ise %1 ile 8.8 arasında görülen beyin omurilik sıvısının toplu hale bulunduğu beyin ventriküllerinin içine olan genellikle hipertansiyona bağlı olma nadiren ise prematuriteye bağlı gelişmemiş yeni doğan koroid pleksuslarının kanamasına bağlı gelişen kanamalardır. Pediyatrik vakalarda çoğunlukla iyi seyrederken erişkin popülasyonda yaklaşık %50 oranında ölümcüldür. İnsidansında anlamlı cinsiyet farkı görülmez. Hem kanama komşuluğundaki önemli yapılar hem beyin omurilik sıvısı dolaşımını bozması hemde kanın tahriş edici etkileri nedeni ile hızlı müdahale edilmezse ölüm ve sakatlıkların önemli nedenidir. (Tenny ve Thorell, 2023). Şekil 2.1’de yukarıda bahsedilen tüm kanama türlerine ait örnek görüntüler gösterilmiştir.



Şekil 2.1. Örnek beyin kanaması görüntüleri (Le ve diğ., 2023)

2.2. Medikal Görüntüleme Teknikleri

Beyin kanaması, hayati tehlike oluşturan ve hızlı teşhis ile acil tedavi gerektiren bir durumdur. Klinik belirtiler güvenilir olmadığından, görüntüleme yöntemleri teşhis için

gereklidir. MRI ve BT yöntemleri, beyin kanamasının teşhisi ve sınıflandırılması amacıyla kullanılan popüler görüntüleme teknikleridir (Solorio-Ramírez ve diğ., 2021).

MRI, manyetik alanlar ve radyo dalgalarını kullanarak vücut dokularının üç boyutlu ve ayrıntılı görüntülerini oluşturur. MRI, özellikle beyin dokusundaki yapıları ve lezyonları görselleştirmede hassastır. Bu teknik, beyin kanamasının nedenlerini anlamaya yardımcı olur ve etkilenen alanların daha iyi değerlendirilmesini sağlar. BT ise X-ışını teknolojisine dayanır ve vücut dokularının kesitsel görüntülerini üretir. Beyin kanaması teşhisinde sıklıkla kullanılır çünkü hızlı bir şekilde kanama alanını ve hacmini tespit edebilir. BT'nin yaygın olarak erişilebilir ve hızlı olması, acil durumlar için önemli bir avantajdır (Yu ve diğ., 2016). Bu görüntüleme teknikleri ile elde edilen verilerin işlenmesi ve yorumlanması için literatürde incelenen makalelerde kullanılan algoritmalar ve yöntemler, beyin kanaması tespitinde önemli bir rol oynamakta ve bu alandaki araştırmaların hızla ilerlemesine katkıda bulunmaktadır. (Yeo ve diğ., 2021)

2.3. Medikal Görüntüleme Dosya Formatları

Tıbbi görüntü dosya formatları iki ana kategoride incelenebilir. İlk kategori, Tıpta Dijital Görüntüleme ve İletişim (DICOM) gibi tanınan görüntüleme cihazları tarafından oluşturulan görüntüleri standardize etmeyi amaçlayan formatları içerir. İkinci kategori, Analyze, Neuroimaging Informatics Technology Initiative (NIfTI) ve Tıbbi Görüntüleme NetCDF (MINC) gibi formatları içerir; bu formatlar, görüntülerin sonrasında işlenmesi ve analiz edilmesini kolaylaştırmayı amaçlar. Tıbbi görüntü dosyaları, genellikle ya metaveri ve görüntü verilerini bir arada tutan tek dosya yapılandırması (DICOM, MINC, NIfTI gibi) veya metaveri ve görüntü verilerini ayrı dosyalarda tutan yapılandırma (Analyze formatı gibi) ile saklanır (Larobina ve Murino, 2014).

Analyze formatı 1980'lerin sonlarında geliştirilmiştir ve uzun süre medikal görüntü işlemede standart olarak kullanılmıştır (Larobina ve Murino, 2014). Çok boyutlu veriler için tasarlanmıştır ancak bazı veri tiplerini desteklememesi ve görüntünün yönünü kesin olarak belirleyecek yeterli bilgiyi saklayamaması gibi dezavantajları vardır.

Analyze formatının sınırlamalarını aşmak için 2000'lerin başında NIfTI formatı geliştirilmiştir. NIfTI formatı, Analyze formatında desteklenmeyen veri tiplerini (örneğin,

işaretsiz 16 bit) destekler. Bu formatta genellikle görüntüler tek bir ".nii" dosyası olarak kaydedilir ve bu dosyada başlık ve piksel verileri birleştirilir. NIfTI formatı birçok yaygın görüntüleme ve görüntü analizi yazılımı tarafından desteklenmektedir. (Gorgolewski ve diğ., 2016).

DICOM, 1980'li yılların başında ortaya çıkan hem bir dosya formatı hem de bir ağ iletişim protokolüdür. Piksel verilerini ve bu verileri oluşturan tıbbi işlemi tanımlayan metaverileri beraber saklar. Bu şekilde görüntünün kendini tanımlayan bir niteliğe sahip olmasını sağlar. DICOM, yalnızca tam sayı değerli piksel verilerini saklayabilir ve verilerin farklı birimlere ölçeklendirilmesi gerektiğinde, bu dönüşümü bir ölçek faktörü kullanarak gerçekleştirir. Ayrıca, DICOM, JPEG, JPEG-LS, JPEG-2000 ve MPEG2/MPEG4 gibi çeşitli sıkıştırma şemalarını destekler. Tıbbi görüntüleme alanındaki yeniliklere uyum sağlama yeteneği ve ağ altyapısı ile bütünleşik bir yapıya sahiptir. (Larobina ve Murino, 2014). Bu format ve protokol, sağlık sektöründe görüntü verilerinin tutarlı bir şekilde saklanması ve paylaşılması için yaygın olarak kullanılır.

2.4. Görüntü Bölütlenmesi

Görüntü bölütlenmesi, bilgisayarlı görü ve dijital görüntü işlemenin önemli bir alt dalıdır. Bu süreç, bir görüntünün farklı kısımlarını veya bölütlerini, benzerliklerine dayanarak kendi sınıf etiketleri altında gruplamayı hedefler. Bu benzerlikler genellikle renk, yoğunluk veya doku gibi özelliklere dayalıdır. Her bir bölüt, görüntünün belirli bir kısmını veya belirli bir özelliği temsil eder. Bu nedenle, bölütleme, görüntüdeki bilgiyi daha anlamlı ve daha kolay analiz edilebilir hale getirir.

Görüntü bölütlenmesi, genellikle görüntü sınıflandırmasının bir uzantısı olarak düşünülür. Görüntü sınıflandırması, görüntünün tamamını tek bir etiketle sınıflandırırken, bölütleme daha ayrıntılı bir analiz sağlar ve görüntüdeki her bir bölgenin neyi temsil ettiğini belirlemeye çalışır. Görüntü bölütlenmesi, sınıflandırmaya ek olarak, yerelleştirme işlemi de gerçekleştirir. Yerelleştirme, belirli bir nesnenin görüntüde tam olarak nerede bulunduğunu belirlemeyi ifade eder. Bu, her bir nesnenin sınırlarını çizen bir model oluşturarak gerçekleştirilir. Bu yönüyle, görüntü bölütleme, görüntü sınıflandırmasının bir üst kümesi olarak düşünülebilir.

Sonuç olarak, görüntü bölütlenmesi, bilgisayarlı görünün karmaşık ve çok yönlü bir alanıdır. Sadece bir görüntünün hangi kısımlarının neyi temsil ettiğini belirlemekle kalmaz, aynı zamanda bu nesnelerin tam olarak nerede bulunduğunu da belirler. Bu, görüntülerin daha anlamlı ve daha ayrıntılı bir şekilde analiz edilmesini sağlar.

2.5. Görüntü Sınıflandırma

Görüntü sınıflandırması, görüntüleri önceden belirlenmiş sınıflara ayırma görevi olarak tanımlanabilir ve bilgisayarlı görünün temel konularından bir tanesidir. Yerelleştirme, tespit etme ve bölütleme gibi diğer bilgisayarlı görü görevlerinin temelini oluşturur (Rawat ve Wang, 2017).

Sınıflandırma işlemini gerçekleştirmek için farklı yöntemler geliştirilmiştir. Genel sınıflandırma prosedürleri, kullanılan yönteme dayalı olarak gözetimli sınıflandırma ve gözetimsiz sınıflandırma olmak üzere iki geniş kategoriye ayrılabilir. Gözetimli sınıflandırmada, araştırmacı görüntülerin hangi sınıfa ait olduğunu belirler. Bu örneklerle ‘eğitim kümesi’ adı verilir ve model bu küme üzerinde öğrenme sürecini gerçekleştirir. Eğitim kümesinin seçimi, araştırmacının konuya olan bilgisine ve tecrübesine bağlıdır.

Diğer yandan, gözetimsiz sınıflandırmada süreç, gözetimli sınıflandırmanın tam tersidir. Burada, önceden belirlenmiş sınıflar yerine, model, verilerde istatistiksel gruplandırmalar veya yapılar belirlemek için kümeleme algoritmaları kullanır. Araştırmacı, genellikle verilerde kaç grup veya kümeyi modelin arayacağını belirtir. Ayrıca, kümeler arasındaki ayrım mesafesini ve her bir küme içindeki varyasyon parametrelerini de belirtilebilir. Gözetimsiz sınıflandırma yöntemi, önceden tanımlanmış bir sınıf kümesi olmadan başlar ve bu nedenle daha karmaşık ve zorlayıcı olabilir. Gözetimli öğrenme, görüntü sınıflandırma problemini çözmek için kullanılan en popüler yöntemlerden biri haline gelmiştir.

3. LİTERATÜR ÖZETİ

Beyin kanamaları, dünya genelinde yaşanan ölümlerin ve sakatlıkların önemli nedenlerinden biridir (Subaiya ve diğ., 2012). Beyin kanamalarının erken teşhis edilmesi ve uygun müdahalelerle hızlı bir şekilde tedaviye başlanması, hastaların hayatta kalma şansını ve yaşam kalitesini önemli ölçüde arttırmaktadır. Günümüzde, tıbbi görüntüleme teknikleri ve gelişen teknolojiler sayesinde beyin kanamalarının tespiti ve analizi giderek daha etkili hale gelmektedir (Bercovich ve Javitt, 2018). Bu çalışmanın amacı, derin öğrenme yöntemlerini kullanarak beyin kanamalarının tespitini yüksek doğruluk ile gerçekleştirmektir.

Literatür incelemesi iki ana bölüme ayrılmıştır. İlk bölümde, beyin kanamalarının yapay zekâ teknikleri kullanılarak tespit edilmesi ele alınmaktadır. Bu bölümde, yapay zekâ ve derin öğrenme yöntemlerinin kanamanın tespit edilmesi sürecine nasıl katkıda bulunduğu odaklanılmıştır. İkinci bölümde ise, beyin kanamalarının bölütlenmesi konusu incelenmiştir. Bu bölümde, mevcut tıbbi görüntüleme tekniklerinin yanı sıra, gelişen bilgisayarlı görü ve yapay zekâ teknolojileri kullanılarak beyin kanamalarının bölütlenmesi için uygulanan yöntemler ele alınmıştır.

3.1. Beyin Kanamalarının Tespit Edilmesi

Literatür incelendiğinde güncel beyin kanaması tespiti çalışmalarında önerilen modellerin genellikle derin öğrenme temelli olduğu tespit edilmiştir. Ancak bu alanda derin öğrenme tekniklerinin yanında makine öğrenmesi ve görüntü işleme temelli yöntemlerin kullanımı da yaygındır. Bu doğrultuda bu alanda yapılan çalışmaları Evrişimli Sinir Ağı (CNN), hibrit model, derin sinir ağları, makine öğrenmesi ve görüntü işleme temelli olarak sınıflandırmak mümkündür.

CNN temelli yöntemler beyin kanaması tespit çalışmalarında yaygın olarak kullanılmaktadır. Bunlardan biri, Kumaravel ve diğ. (2021) tarafından geliştirilen ve CQ500 veri kümesi üzerinde eğitilmiş AlexNet-SVM (Destek Vektör Makineleri) sınıflayıcısıdır. Bu çalışma, beyin BT görüntülerinde Travmatik Beyin Hasarı (TBI) tespiti için %99,86 sınıflandırma doğruluğu ve 0,9986 hassasiyet ve özgüllük elde etmiştir. Ancak, bu çalışmada veri kümesinin tamamı kullanılmamıştır. Normal kategori

için, toplam kesit sayısı TBI kategorisindeki toplam kesit sayısına eşit olacak şekilde seçilmiştir. Görüntüler ise rastgele seçilmiştir. Başka bir çalışmada (Singh ve diğ., 2021), optimize edilmiş 3D Görsel Geometri Grubu (VGG) mimarisi kullanılarak beyin BT görüntülerinin sınıflandırılması için sıg 3D CNN mimarisi sunulmuştur. Bu yöntem, 3D VGGNet ve 3D ResNet mimarileri ile karşılaştırıldığında, önerilen model daha az eğitim süresi, daha az eğitilebilir parametre ile daha yüksek doğruluğa ulaşabilmiştir.

Asif ve diğ. (2023) yaptıkları çalışmada İntrakraniyal Kanama (ICH) tespiti ve alt tiplerinin sınıflandırılması için yeni bir metodoloji önermişlerdir. Önerilen çözüm, ResNet101-V2, Inception-V4 ve Hafif Gradyan Artırma Makinesi (LGBM) kullanılarak oluşturulmuştur. ResNet101-V2 mimarisi, dilimlenmiş görüntülerden potansiyel özellikleri çıkarmak için kullanılırken, Inception-V4 mimarisi önemli uzamsal bilgiyi yakalamak için kullanılmıştır. Bu çıktılar, ICH tespiti ve alt tiplerinin sınıflandırılması için LGBM yöntemi ile işlenmiştir. Yöntem, CQ500 ve Kuzey Amerika Radyoloji Derneği (RSNA) veri kümelerinde eğitilip test edilmiştir. RSNA veri kümesinde %97,7 doğruluk, %96,5 duyarlılık ve %97,4 F1 skorları elde etmişlerdir. Başka bir çalışma ise, (Cortés-Ferre ve diğ., 2023) RSNA veri kümesi üzerinde eğitilmiş EfficientDet yöntemiyle beyin kanaması tespiti ve teşhisini gerçekleştirmektedir. Önerilen model ile %92,7 doğruluk ve %97,8 ROC AUC başarısı elde etmişlerdir. RSNA veri kümesini kullanan bir diğer çalışma ise Burduja ve diğ. (2020) tarafından gerçekleştirilmiştir. Çalışmada intrakraniyal kanama tespiti ve sınıflandırması için bir sistem önerilmektedir. Önerilen sistem, bir CNN ve Uzun-Kısa Süreli Bellek (LSTM) ağından oluşan hafif bir derin öğrenme modeli kullanmaktadır. Çalışma sonucunda beyin kanaması tespitinde %96,00 doğruluk elde etmişlerdir. Bunun yanı sıra, Karki ve diğ. (2020) tarafından, farklı pencerelerde ölçeklendirilmiş birden fazla görüntü sağlayarak anormalitenin tespitini gerçekleştiren bir çalışma bulunmaktadır. Bu yöntem ile de %96,43 doğruluk elde etmişlerdir.

Buraya kadar, literatürdeki beyin kanaması tespiti ve sınıflandırması yapan güncel çalışmalardan, yalnızca CNN tabanlı yöntemleri kullananlara değinilmiştir. Bu çalışmalara ek olarak hibrit algoritmalar ve çoklu model kullanımı da literatürde önemli bir yere sahiptir. Hibrit algoritmalar, iki veya daha fazla derin öğrenme modelini veya sınıflandırma yöntemini birleştirerek daha güçlü ve etkili çözümler sunmayı

hedeflemektedir. Bu tür algoritmalar, farklı modellerin güçlü yönlerini kullanarak daha yüksek performans elde etmeyi amaçlar. Bu yaklaşımla, her modelin avantajlarını ve dezavantajlarını dengeleyerek daha doğru ve güvenilir tespit ve sınıflandırma sonuçları elde edilebilir.

Ozaltin ve diğ. (2023), tarafından PhysioNet veri kümesinden elde edilen beyin kanaması BT görüntülerini sınıflandırmak için %99,58 doğruluk sağlayan bir yöntem geliştirilmiştir. Bu yöntem, CNN algoritması ve Komşuluk Bileşen Analizi (NCA) ile özellik çıkarma ve azaltma süreçlerini kullanarak sınıflandırma performansını artırmaktadır. Çalışmada, veri kümesinde yer alan bazı sınıfların örnek sayısının düşük olması nedeniyle silindiği ve bu durumun sınıflandırma sürecine etkisi olduğu belirtilmiştir. Böylece, kalan sınıflar üzerinden daha güçlü ve etkili bir sınıflandırma modeli oluşturulmuştur. Beyin BT görüntülerindeki intrakraniyal kanamaları tespit etmek ve sınıflandırmak amacıyla gerçekleştirilen bir başka çalışmada (Wang ve diğ., 2020) hibrit model önermişlerdir. Bu model, bir bölgeye ait özellikleri belirlemek için iki bölüme ayrılan bir sinir ağı kullanmaktadır. Daha sonra bu özellikler, Koşullu Rasgele Alan (CRF) modelini temel alan bir mesaj geçişi modülü ile iyileştirilmiştir. Bu yöntem, RSNA veri kümesiyle test edildiğinde F1 skoru olarak 0,7482 elde edilmiştir. Santhoshkumar ve diğ., (2021) PhysioNet veri kümesi üzerinde %96,34 doğruluk sağlayan hibrit bir yöntem geliştirmişlerdir. Yöntemde Tsallis entropi ve Çekirge Optimizasyon Algoritması (GOA) ile geliştirilen TEGO algoritması ile görüntü bölütlenmesi gerçekleştirilmiş, DenseNet ile özellik çıkarımı gerçekleştirilmiş ve son olarak Aşırı Öğrenme Makinesi (ELM) ile görüntü sınıflandırması yapılmıştır.

Beyin kanaması tespiti amacıyla kullanılan güncel yöntemlerden bir diğeri de derin sinir ağları temelli modellerdir. Zhang ve diğ. (2023) RSNA veri kümesi üzerinde zayıf gözetimli yönlendirilmiş dikkat mekanizması kullanarak %98,1 doğruluk ve %74,6 F1 skoru elde etmişlerdir. Phan ve diğ. (2021) yaptıkları çalışmada, transfer öğrenme ve U-Net modelini kullanarak 3D BT görüntülerinden beyin kanaması tespiti gerçekleştirmişler ve %92,5 doğruluk elde etmişlerdir. Son olarak, Anupama ve diğ. (2022) PhysioNet veri kümesi üzerinde GrabCut tabanlı bölütleme ve Gabor filtreleme kullanarak sinerjik derin öğrenme ile %95,73 doğruluk elde etmişlerdir. Derin sinir ağları temelli modeller,

karmaşık özellik çıkarma ve sınıflandırma yetenekleri sayesinde, beyin kanaması tespitinde önemli başarılar elde etmiştir.

Literatürde makine öğrenimi algoritmalarını kullanarak beyin kanaması tespiti yapan güncel çalışmalar da mevcuttur. Solorio-Ramírez ve diğ. (2021), Minimalist Makine Öğrenimi (MML) paradigması ve dMeans temelli yeni bir model sınıflandırma metodolojisi geliştirerek, BT görüntülerini sınıflandırmak için çeşitli sınıflandırıcılarla karşılaştırmıştır. Bu yöntem, çalışmaya özgü olarak oluşturulan veri kümesinde yer alan 627 görüntüleri kullanarak %86,50 doğruluk ve %91,60 özgülük elde etmiştir. Çalışma karmaşıklığı azaltarak ve anlaşılabilirliği artırarak X-AI trendini takip etmektedir. Chen ve diğ. (2020) tarafından gerçekleştirilen başka bir çalışmada akıllı Nesnelerin İnterneti (IoT) tabanlı uygulamaları desteklemek için beyin kanaması teşhisi sağlamak amacıyla destek vektör makinesi ve ileri besleme yapay sinir ağı kullanarak bir çözüm önerilmiştir. PhysioNet veri kümesi üzerinde yapılan deneylerde, destek vektör makinesi yöntemi kullanılarak %80,67 ve ileri besleme yapay sinir ağı kullanılarak %86,7 doğruluk elde etmişlerdir. Çalışma sonucunda ileri besleme yapay sinir ağı, intrakraniyal görüntüleri sınıflandırmada daha başarılı bulunmuştur.

Tüm bu yaklaşımlara ek olarak daha geleneksel olan görüntü işleme ve bölütleme tekniklerini kullanarak beyin kanaması teşhisi yapan çalışmalar da mevcuttur. Zhang ve diğ. (2021) tarafından önerilen model ile, çalışmaya özgü veri kümesi kullanılarak, yapay lezyon sentezi yöntemiyle ek etiketli eğitim örnekleri üretilmiştir. Bu yöntem AUC değerini, TBI tespiti için %84'ten %91'e ve sınıflandırma için %89'dan %96'ya kadar arttırmıştır. Diğer bir çalışmada (Pai, 2022), eşikleme, median filtreleme ve bağlı bileşen etiketleme yöntemleri kullanılarak beyin BT görüntülerinin bölütlenmesi gerçekleştirilmiştir.

3.2. Beyin Kanamalarının Bölütlenmesi

Derin öğrenme tabanlı yöntemler, özellikle CNN ve U-Net, beyin kanama bölütlenmesi için yaygın olarak kullanılmaktadır. Inkeaw ve diğ. (2022), çalışmalarına özgü olarak oluşturulan veri kümesi üzerinde üç boyutlu bir CNN olan DeepMedic modelini kullanarak travmatik beyin hasarı (TBH) tespiti yapmışlardır. Geliştirilen model, SDH, Epidural Kanama (EDH) ve İntraparankimal Kanama (IPH) olarak adlandırılan üç

kanama alt türünü otomatik olarak bölütlemek için kullanılmıştır. Bu çalışmada, SDH, EDH ve IPH sınıfları için sırasıyla 0.58, 0.64 ve 0.35 medyan hassasiyet değerleri elde edilmiştir. Hssayeni ve diğ. (2020)'nin çalışmasında ise, PhysioNet veri kümesi üzerinde bir derin evrişimli ağ (FCN) olan U-Net ile TBI bölütlenmesi yapılmıştır ve 0,31 Dice katsayısı elde edilmiştir. Bir başka çalışmada (Xu ve diğ., 2021), özel bir veri kümesi kullanılarak Yoğun U-Net çerçevesi ile bölütleme ve hacim değerlendirmesi için 0,9'lık bir Dice katsayısı elde edilmiştir. Phan ve diğ. (2020) ise, kendi oluşturdukları özel bir veri kümesi üzerinde Hounsfield birimi ve Faster R-CNN Inception kullanarak beyin kanamalı bölgelerin bölütlenmesi ve sınıflandırması amacıyla ortalama hassasiyet değerini (mAP) %79 olarak elde etmiştir. Son olarak Yao ve diğ. (2020), akut kanamaları bölütlemek için çoklu görünüm konvolüsyonel sinir ağı (MVCNN) ve karma kayıplı yöntem önermişlerdir. Önerilen yöntem ile test kümesinde ortalama 0,697'lik Dice katsayısı ve 0,966'lık sınıf içi korelasyon katsayısı elde etmişlerdir.

Bölütleme problemi için CNN tabanlı yöntemlerin etkili olduğu görülse de alternatif yaklaşımlar da mevcuttur. Kümeleme ve kontur tabanlı yöntemler, intrakraniyal kanama bölütlenmesi ve analizinde alternatif bir yaklaşımdır. Bu yöntemleri temel alan çalışmalar beyin içi kanama bölütlenmesi için farklı veri kümeleri üzerinde etkili sonuçlar elde etmiştir. Kumar ve diğ. (2022), entropi temelli bir yöntem kullanarak 35 BT görüntüsü üzerinde 0,930'lık Dice katsayısı ve 0,860'lık Jaccard katsayısı elde etmiştir. Yao ve diğ. (2019), aktif öğrenme stratejisi ve aktif kontur modeli kullanarak, farklı sağlık merkezlerinden ve yaralanma düzeylerindeki hastaların yer aldığı veri kümesinde ortalama 0,60'lık bir Dice katsayısı elde etmiştir. Tu ve diğ. (2019) çalışmasında ise, düzenleştirilmiş mekânsal bulanık C-means kümeleme ve kenarsız aktif kontur yöntemini kullanarak, 30 hastanın veri kümesinde kanama bölütlenmesi için ortalama 0,92'lik bir Dice katsayısı elde etmiştir. Bhadauria ve diğ. (2021) ise, beyin BT görüntülerinde kanama bölgelerini çıkarmak için seviye kümeleme bölümlleme yöntemi ile bulanık kümeleme özelliklerini kullanarak bölütleme yapmışlardır. Bu yöntem, 300 beyin BT görüntüsü üzerinde uygulanmış ve piksel bazında doğruluk oranı %85,40 olarak bulunmuştur.

Bu çalışmalar, kümeleme ve kontur tabanlı yöntemlerin beyin içi kanama bölütlenmesi için etkili ve güvenilir bir yaklaşım olduğunu göstermektedir.

Subdural kanama bölütlenmesi amacıyla gerçekleştirilen bir diğer önemli çalışmada (Farzaneh ve diğ., 2020), 110 görüntü içeren özel bir veri kümesi üzerinde klasik görüntü işleme ve derin öğrenme kombinasyonunu kullanan bir makine öğrenimi hattı geliştirilmiştir. Bu çalışmada, el ile çıkartılan özellikler ve derin özelliklerin kombinasyonu kullanılarak her noktanın kanama bölgesine ait olma olasılığı belirlenmiştir. Önerilen bölütleme yöntemi, tüm veri kümesi için %75,35'lik Dice benzerlik katsayısı elde etmiş olup, klinik olarak önemli kanamalar için %79,97'lik bir katsayı sağlamıştır.

Li ve diğ. (2022) , ilk kez kanama genişlemesini bölütleme mimarisine dahil eden ve dilimler arasındaki bağlamsal bilgiyi etkili bir şekilde aktaran bir yöntem önermişlerdir. Çalışma 250 adet BT taraması üzerinde gerçekleştirilmiştir. Önerilen yöntem ile Dice katsayısı 0,86 olarak bulunmuştur.

Hem bölütleme ve sınıflandırma problemleri açısından gerçekleştirilen literatür incelemesi sonucunda, her iki problem için uygun teknikler belirlenmiştir. Bölütleme süreci için literatürde başarılı olarak sayılan Mask R-CNN, Cascade Mask R-CNN, MS R-CNN, Hybrid Task Cascade, You Only Look At CoefficientTs (YOLACT), QueryInst ve Sample Consistency Network (SCNet) modelleri seçilmiştir. Sınıflandırma süreci için ise VGG, Kalıntı Ağı (ResNet) ve EfficientNet modelleri incelenmiştir. Bu modeller, derin öğrenme tabanlı sınıflandırma modelleri olup, literatürde performansları ve hızları ile öne çıkmaktadırlar.

4. MATERYAL VE YÖNTEM


Bu bölümde, beyin kanaması tespiti için kullanılan veri kümesi, geliştirme ortamı, sınıflandırma ve bölütleme teknikleri, değerlendirme ölçütleri ve önerilen hibrit beyin kanaması tespit yöntemi hakkında detaylı bilgi verilmektedir. Birinci alt bölümde, çalışmanın temelini oluşturan ve analizlerin gerçekleştirildiği veri kümeleri hakkında bilgi verilecektir. Geliştirme ortamı bölümünde, bu çalışmanın hangi yazılım ve donanım ortamında yapıldığına dair bilgiler paylaşılacaktır. Sınıflandırma ve bölütleme teknikleri bölümlerinde, tez çalışması kapsamında beyin kanamasının tespiti için kullanılan metodoloji ve teknikler anlatılacaktır. Değerlendirme ölçütleri bölümünde ise, performans değerlendirmesi amacıyla kullanılan metrikler ve ölçütler hakkında bilgi verilecektir. Son olarak, önerilen hibrit beyin kanaması tespit yöntemi bölümünde, tezde sunulan hibrit tespit yöntemi hakkında ayrıntılı bilgi verilecektir.

4.1. Veri Kümeleri

Beyin kanaması görüntülerinin tespiti ve bölütlenmesi karmaşık ve hassas bir süreçtir. Bu problemin doğruluğu, kullanılan veri kümesinin kalitesine ve genişliğine büyük ölçüde bağlıdır. Ancak geniş çaplı ve kaliteli açık veri kümelerine ulaşılması bu alanda çalışma yapan araştırmacılar için önemli bir sorun teşkil etmektedir. Bu alanda işaretli veri, yani beyin kanamasının bulunduğu konumu belirten özelliklere sahip veriler sınırlıdır. Bu durumun başlıca sebepleri arasında uzmanlık ve zaman gerektiren işaretleme sürecinde görev alacak gönüllü uzmanların bulunması konusunda yaşanan zorluk yatmaktadır. Bir diğer sebep ise medikal görüntüleme verileri üzerinde çalışırken, hissedilen gizlilik ve etik kaygılardır. Tez kapsamında yöntemlerin eğitilmesi ve değerlendirilmesi için iki adet açık veri kümesinden yararlanılmıştır. Bunlar CQ500 (Chilamkurthy ve diğ., 2018) ve PhysioNet (Hssayeni ve diğ., 2020) veri kümeleridir.


CQ500 veri kümesi, BT görüntülerini içerir ve bu görüntüler kanama, kırık, orta hat kayması ve kitle etkisi gibi çeşitli beyin durumlarını temsil eder. Bu veri kümesi, 2018 yılında Hindistan'da, Chilamkurthy ve ekibi tarafından oluşturulmuştur. Bu ekip, görüntülerin etiketlemesini üç uzman radyologun yardımıyla manuel olarak gerçekleştirmiştir. Veri kümesi 491 taranmış BT kümesi ve TBI'ları bölütlemek için uygun yaklaşık 200.000 dilim içermektedir. Veri kümesi, bölütleme için uygun olarak

etiketlenmiş görüntüler içermemektedir. Bu nedenle, SDH kanama içeren taramalar önce uzman bir doktor tarafından işaretlenmiştir. Şekil 4.1'de işaretlenmiş tarama görüntülerinden bazıları örnek olarak gösterilmektedir.



Şekil 4.1. CQ500 veri kümesinden etiketli örnek taramalar

PhysioNet veri kümesi, TBI olan hastaların BT taramalarını içerir. Veri kümesi 2018 yılının şubat ve ağustos ayları arasında Irak'taki Al Hilla Öğretim Hastanesi'nden toplanmıştır. Veri kümesindeki taramalar, iki deneyimli radyolog tarafından titizlikle incelenmiş ve her bir BT kesiti, kanama türlerine göre etiketlenmiştir. Ek olarak, her bir BT kesitinde TBI bölgeleri, radyologlar tarafından belirlenmiş ve etiketlenmiştir. Veri kümesi, toplamda 2812 BT kesiti içermektedir. Bunların 2494'ü sağlıklı kesitler olup, bu kesitler TBI belirtisi göstermeyen, yani beyin hasarı veya kanama içermeyen kesitlerdir. Diğer 318 kesit ise beyin kanaması içerir (Hssayeni ve diğ., 2020). Şekil 4.2'de işaretlenmiş tarama görüntülerinden bazıları örnek olarak gösterilmektedir.



Şekil 4.2. PhysioNet veri kümesinden etiketli örnek taramalar

Tablo 4.1. Veri kümelerine genel bakış tablosu

Veri Kümesi	Veri Sayısı	Veri Dağılımı	Tarama Kalınlığı	Okuyucu Sayısı
CQ500	491 BT Taraması	205 Beyin Kanaması 40 Kafatası Kırığı 65 Orta Hat Kayması 127 Kafa Travması 54 Sağlıklı Tarama	0,625 mm, 3 mm, 5 mm	3 Radyolog
PhysioNet	75 BT Taraması	36 Beyin Kanaması 39 Sağlıklı Tarama	5 mm	2 Radyolog


4.2. Sınıflandırma Teknikleri

Tez kapsamında beyin kanamalarının sınıflandırılması amacıyla günümüzde farklı sınıflandırma problemlerinde yaygın olarak kullanılan 3 farklı konvolüsyonel ağ mimarisi kullanılmıştır. Tezin bu bölümde kullanılan mimarilerinin detaylı açıklamaları verilmiştir. Sınıflandırma teknikleri bölümü (Gençtürk ve diğ., 2023) çalışmamızdan alıntılanmıştır.

4.2.1. VGG (Visual Geometry Group)

VGG(Simonyan ve Zisserman, 2014) büyük ölçekli veri kümelerinde görüntü tanıma yapabilmek amacıyla geliştirilmiş birden fazla katmana sahip standart bir CNN mimarisidir. Yenilikçi nesne tanıma modellerinin temelini oluşturmaktadır. Çalışmada VGG'nin özel mimarileri olan VGG-11, VGG-13 ve VGG-16 kullanılmıştır. VGG-11 mimarisi 8 evrişim katmanı ve 3 tam bağlantılı katmandan oluşur.

Girdi olarak 224x224x3 boyutlarında RGB görüntüleri alır. Mimari içerisinde ilerledikçe derinleşmektedir ve parametre sayıları artmaktadır. Parametre sayıları havuzlama katmanları sayesinde azaltılır. VGG-11 içerisinde havuzlama katmanları her aşamada kullanılmak yerine ağ içerisinde dağıtık halde bulunmaktadır. Son aşamada ise sınıflandırmayı gerçekleştirmek için softmax sınıflandırıcısı kullanılır. VGG-11 mimarisi Şekil 4.3'de gösterilmiştir.



Şekil 4.3. VGG-11 ağ mimarisi

VGG-13 ve VGG-16 mimarileri VGG-11 mimarisi ile ortak girdi ve çıktı katmanlarına sahiptir. Mimariler evrişimli katmanların bulunduğu ve özellik çıkarımı yapılan kısımda özelleşmektedir. Mimarilerin katmanları ve farklılaştıkları kısımlar Tablo 4.2’de gösterilmektedir.


Tablo 4.2. VGG ağ mimarisi genel katman tablosu

Model	Özellik Çıkarımı				
	1. Blok	2. Blok	3. Blok	4. Blok	5. Blok
VGG-11	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
			Conv3-256	Conv3-512	Conv3-512
VGG-13	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
VGG-16	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
	Conv3-64	Conv3-128	Conv3-256	Conv3-512	Conv3-512
			Conv3-256	Conv3-512	Conv3-512

VGG mimarilerinde konvolüsyon katmanları özellik çıkarıcı olarak 5 blok halinde incelenebilir. Her blok içerisinde küçük boyutlu (3x3) filtreler kullanılmaktadır. VGG-11 ve VGG-13 tasarımlarını birbirinden ayıran sadece ilk iki bloktaki seviye sayısıdır. VGG-11 mimarisinden VGG-13 mimarisini oluşturmak için aynı konfigürasyona sahip ilk iki blok eklenir. Buna benzer şekilde, VGG-16 ve VGG-19 tasarımları üçüncü bloktan beşinci bloğa kadar kademeli olarak katmanlar eklenerek oluşturulur. Aynı zamanda özellik uzayını yoğunlaştırmak için her bloğun sonuna bir maksimum havuzlama katmanı eklenir. Maksimum havuzlama katmanında 2 adımlı bir (2x2) filtre kullanılır.

4.2.2. ResNet (Residual Neural Network)

ResNet (He ve diğ., 2016) özel bir CNN mimarisidir ve yalnızca konvolüsyon katmanlarından oluşur. Temelde katman bloklarının kısayol bağlantıları kullanılarak atlanması fikrini gerçekleştirmektedir. Her iki katmanda bir artık bağlantılar kullanır. Bir artık bağlantı, konvolüsyon ağının çıktısını takip eden konvolüsyonel katmanının çıkışına bağlar. Özellik haritalarının çözünürlüğü ve kanal sayısı ağ içerisinde ilerledikçe azalmaktadır. Buna ek olarak evrişim filtrelerinden sonra, bir ortalama havuzlama katmanına, tahmin yapmak için ise mimarinin çıkışında tam bağlantılı katmana sahiptir. Aynı zamanda modelin artık ağlar dışında devam eden çıktıları ve artık evrişim katmanlarının girdilerini birleştirmek için basit bir toplam uygulanır. Bu şekilde özellik haritasının artıklarını kullanarak gerçekleştirilen bir eğitimin sadece özellik haritasının kullanıldığı bir eğitimden daha verimli olduğu görülmüştür(He ve diğ., 2016). ResNet ağının 18 katman, 34 katman ve 101 katman gibi değişen parametrelerde katman sayısı içeren çeşitli mimarileri bulunmaktadır. ResNet-50'nin genel mimarisi Şekil 4.4'de gösterilmiştir.



Şekil 4.4. ResNet-50 ağ mimarisi

Tablo 2’de çalışmada kullanılan iki model olan ResNet-50 ve ResNet-101 mimarilerinin katmanları detaylı olarak gösterilmiştir.

Tablo 4.3. ResNet ağ mimarisi genel katman tablosu


Model	Özellik Çıkarımı				
	1. Blok	2. Blok	3. Blok	4. Blok	5. Blok
ResNet-50	7x7, 64, Stride 2	3x3, MaxPool, Stride 2	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$

Tablo 4.3. ResNet ağı mimarisi genel katman tablosu (Devam)

		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$			
ResNet-101		3x3, MaxPool, Stride 2	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$			

4.2.3. EfficientNet

EfficientNet (Tan ve Le, 2019) daha az parametreye sahip ve sınıflandırma doğruluğunu artıran CNN modelleri tasarlamak amacıyla geliştirilmiştir. Genişliği, derinliği ve çözünürlüğü eşit olarak ölçeklendirmek için bileşik ölçeklendirme tekniğini ve mobil ters çevirilmiş darboğaz konvolüsyonunu (MBConv) kullanır. MBConv blokları kanalları genişleten ve ardından sıkıştıran bir katmandan oluşur. Bu tasarım, geleneksel katmanlara kıyasla hesaplamayı neredeyse k^2 oranında azaltan derin ayrılabilir konvolüsyonlar içerir; burada k, 2D konvolüsyon penceresinin genişliğini ve yüksekliğini temsil eden çekirdek boyutudur (Sandler ve diğ., 2018). EfficientNet-B0'dan EfficientNet-B7'ye kadar yedi farklı mimariye sahiptir. EfficientNet-B0 modelinin şematik gösterimi Şekil 4.5'te verilmiştir.



Şekil 4.5. EfficientNet-B0 ağı mimarisi

Şekil incelendiğinde MBConv1, MBConv3 ve MBConv6 bloklarının tekrarlanarak kullanıldığı görülmektedir. Bunlar MBConv bloğunun farklı biçimleridir. Şekilde her bir blok içindeki kanal sayısının daha fazla sayıda filtre kullanılarak artırıldığı veya

büyütüldüğü de görülmektedir. EfficientNet mimarisinin sekiz farklı modeline ait özellikler Tablo 4.4'te verilmiştir.

Tablo 4.4. EfficientNet modellerine ait genel özellik tablosu

Model	Katman Sayısı	Giriş Çözünürlüğü	Özellik Vektör Boyutu
EfficientNet-B0	240	224x224	1280
EfficientNet-B1	342	240x240	1280
EfficientNet-B2	342	260x260	1408
EfficientNet-B3	387	300x300	1536
EfficientNet-B4	477	380x380	1792
EfficientNet-B5	579	456x456	2048
EfficientNet-B6	669	528x528	2304
EfficientNet-B7	816	600x600	2560

Tablo 3 incelendiğinde EfficientNet-B0'dan B7'ye kadar, giriş çözünürlükleri gibi katman sayısının da değiştiği görülmektedir. EfficientNet-B7 ise EfficientNet-B0'dan yaklaşık 3,50 kat daha derindir. Çalışmamızda EfficientNet modellerinden ilk dördü (B0-B4) kullanılarak BT görüntülerinden beyin kanamasının sınıflandırılması yapılmıştır.

4.3. Bölütleme Teknikleri


Çalışma kapsamında subdural beyin kanamalarını tespit etme performansları açısından yedi farklı bölütleme yönteminin sekiz farklı mimarisini karşılaştırılmıştır. Bu bölümde bu yöntemlerin tanımları ve aralarındaki ana farklılıklar verilmektedir. Bölütleme teknikleri bölümü (Gençtürk ve diğ., 2023) çalışmamızdan alıntılanmıştır.

4.3.1. Mask R-CNN

Mask R-CNN(He ve diğ., 2017), Faster R-CNN (Ren ve diğ., 2015) algoritması üzerine kurulu bir nesne bölütleme yöntemidir. Fast R-CNN'i oluşturan iki aşama vardır. Potansiyel nesne sınırlayıcı kutuları öneren ilk aşamaya bölge önerisi ağı (RPN) denir (Girshick, 2015). İkinci aşama, ilgi bölgesi havuzlama (RoIPooling) olarak bilinir. Bu aşamada, her aday kutudan özellikler alınır ve sınırlayıcı kutu regresyonu gerçekleştirilir. Faster R-CNN gibi Mask R-CNN de iki aşamalı bir süreç kullanır. İkinci adımda, sınıfı

ve kutu sınırlarını tahmin etmek için her ilgi bölgesi (ROI) için eşzamanlı bir ikili maske oluşturulur.


Bu çalışmada kullanılan Mask R-CNN ağının üç modülü bulunmaktadır. İlk modül, ResNet-50 + özellik piramit ağı (FPN) + RPN oluşan özellik çıkarımını ve ROI oluşturmayı gerçekleştirir. İkinci modül, ilk modülden elde edilen ROI'lerin boyutlarını düzeltir ve hizalama hatalarını önler. Bu modül ilgi bölgesi hizalama (RoiAlign) olarak adlandırılır. Üçüncü modül, maske edinme olarak adlandırılabilir. İkinci modülden alınan sabit boyutlu ROI'ler, bu modüldeki bölge bölütleme ağına gönderilir. Bu çalışmada, Mask R-CNN yöntemi, omurga ağında ResNet-50 ve ResNet-101 kullanılarak iki farklı mimari ile çalıştırılmıştır. Şekil 4.6, kullanılan Mask R-CNN mimarisinin görsel bir temsili olarak gösterilmektedir.



Şekil 4.6. Mask R-CNN'nin genel mimarisi

4.3.2. Cascade Mask R-CNN

Cascade Mask R-CNN (Cai ve Vasconcelos, 2019), nesnenin konumunu ve bölütleme doğruluğunu aşamalı bir şekilde geliştiren bir kademeli öğrenme yöntemi kullanır. İlk aşama, Mask R-CNN'deki gibi, ROI özelliklerini alır ve sınıflandırma ve regresyon işlemlerini gerçekleştirir. Cascade R-CNN mimarisinde her tahmincinin çıktısı, sonraki tahminci için giriş olarak kabul edilir. Dahası, her tahminci, başlangıç dağılımı yerine önceki tahminci tarafından tahmin edilen yerelleştirme dağılımı ile desteklenir. Kademeli ağların son aşamasında, regresyon ve sınıflandırma ile bölütleme gerçekleştirilir. Cascade R-CNN'nin genel mimarisi Şekil 4.7'de verilmiştir. Çalışmamızda kullanılan ağ tasarımında, ResNet-50 ağı omurgası olarak hizmet eder. Giriş olarak aldığı BT görüntüsünden, ResNet-50 omurgası özellik haritaları oluşturur. Oluşturulan özellikler, potansiyel aday konumları tahmin eden RPN'ye gönderilir. Cascade R-CNN'nin başlangıç aşamasında, ağ çıktısı RPN modülü önerilerini ve FPN modülü özellik haritalarını alır, ardından sınıflandırır.




Şekil 4.7. Cascade Mask R-CNN genel mimarisi

4.3.3. Mask Scoring R-CNN

MS R-CNN(Huang ve diğ., 2019), Mask R-CNN'nin geliştirilmiş bir versiyonudur. Doğruluğu artırmak için, MS R-CNN ağıın çıktısına bir MaskIoU başlığı ekler. Bu, oluşturulan maskelerin puanlanmasını sağlar. Maske puanlama süreci iki aşamadan oluşur. İlk olarak, doğru örnekle bir maske oluşturulur, ardından arka plan için MaskIoU geliştirilir (Huang ve diğ., 2019).

MS R-CNN'nin dört ana aşaması vardır, ilk 3'ü Mask R-CNN'ye eşdeğerdir. İlk olarak, ResNet-101+FPN ile oluşturulan bir omurga mimarisi kullanılarak özellikler çıkarılır. İkinci aşamada, RPN'nin çıktısı olarak aday ROI'ler önerilir. Üçüncü adımda, her aday ROI'den RoIAalign kullanılarak özellikler çıkarılır, bir bölütleme maskesi çıktısı oluşturulur. Dördüncü aşamada, MaskIoU, tahmin edilen ve gerçek maske arasında bir puan oluşturulur. MS R-CNN'nin genel mimarisi Şekil 4.8'de verilmiştir.




Şekil 4.8. MS R-CNN genel mimarisi

4.3.4. Hybrid Task Cascade

Hybrid Task Cascade (HTC) (Chen ve diğ., 2019), bölütleme, sınırlayıcı kutu algılama ve maske tahmin görevleri arasındaki ilişkiyi kurmayı hedefleyen bir nesne tespiti ve bölütlenmesi mimarisidir (Fang ve diğ., 2021). Mevcut bölütleme yöntemlerinden farklı olarak önceki katmandan elde edilen maske özellikleri ile mevcut aşamayı besleyerek maske dalları arasındaki bilgi akışını güçlendirir. Ek bir anlamsal bölütleme dalını


maske ve sınırlayıcı kutu dallarıyla birleştirerek daha fazla bağlamsal bilgiyi keşfetmeyi amaçlar (Chen ve diğ., 2019). Şekil 4.9’te HTC yönteminin genel mimarisi gösterilmiştir.



Şekil 4.9. Hybrid Task Cascade genel mimarisi

4.3.5. YOLACT

YOLACT temelde Mask R-CNN, Faster R-CNN ilişkisinde olduğu gibi mevcut tek aşamalı nesne algılama modeline bir maske dalı eklemeyi hedefler (Bolya ve diğ., 2019). Bu amaçla bölütleme süreci paralel çalışacak şekilde iki adet göreve bölünmüştür. İlk görev bir dizi prototip maske üretmek ve ikinci görev ise örnek başına maske katsayılarını tahmin etmek olarak özetlenebilir. Prototip maskesi üretmek için FCN mimarisini kullanır ve örnek başına bir dizi doğrusal kombinasyon katsayısı tahmin eder. Daha sonra, prototipleri maske katsayılarıyla doğrusal olarak birleştirerek örnek maskeler üretir (Bolya ve diğ., 2019). Şekil 4.10’te YOLACT yönteminin genel mimarisi gösterilmiştir.




Şekil 4.10. YOLACT genel mimarisi

4.3.6. QueryInst

QueryInst (Fang ve diğ., 2021), sorgu tabanlı bir bölütleme yöntemidir. Paralel şekilde çalışabilen altı dinamik maske başlığı ve bir adet sorgu tabanlı nesne tespiti çıkışı kullanır. Herhangi bir sorgu tabanlı nesne tespit ağı üzerine kurulabilir. Varsayılan olarak altı sorgu aşamasına sahip Sparse R-CNN(Sun ve diğ., 2021) kullanılmaktadır.

QueryInst nesne tespitine ek olarak sorgu tabanlı çalışabilen bir maske tahmin başlığı kullanmaktadır. Mask R-CNN mimarisinde kullanılan maske başlığından farklı olarak paralel olarak çalışabilen dinamik bir maske başlığına sahiptir. Bu dinamik tasarım ile paralel maske katmanı tarafından yönlendirilen sorgularda maske başlığına bilgi akışı sağlanmaktadır ve bu şekilde örnek bölütlenmesi için iletişim güçlendirilmektedir (Fang ve diğ., 2021). Şekil 4.11’da QueryInst yönteminin genel mimarisinde bulununan 6 sorgu aşamasından 2 tanesi gösterilmiştir.




Şekil 4.11. Dinamik maske kafasına sahip QueryInst'e genel bakış. (6 aşamadan 2 tanesini göstermektedir). (Fang ve diğ., 2021)

4.3.7. SCNet

Örnek Tutarlılık Ağı (SCNet)(Vu ve diğ., 2021), örnekleme bölütlenmesi yöntemi olarak, eğitim sırasında elde edilen kesişim bölgelerinin çıkarım zamanındaki dağılıma yakın olmasını sağlar. Bu, kademeli bir nesne bölütlenmesi yaklaşımıdır ve mevcut kademeli yöntemlerin eksikliklerini geliştirmeyi hedefler. Cascade Mask R-CNN gibi önde gelen yöntemler birden fazla nesne dedektörü kullanır, bu da bölütleme ve nesne tespiti üzerinde gelişme sağlar. HTC, Cascade Mask R-CNN'nin geliştirilmiş bir versiyonudur

ve bölütleme maskesinin oluşturulmasından sorumlu katmanlar arasında bilgi akışını sağlar.

SCNet, eğitim ve çıkarım aşamalarının tutarlı bir şekilde gerçekleştirilmesiyle performansın daha da iyileştirilebileceğini gösterir. Dahası, SCNet, tespit ve bölüt tahminleme işlemini gerçekleştirdiği havuz katmanına ek olarak, her nesnenin çevresi ile olan bağlantısını da inceleyerek belirsiz nesnelerin üstesinden gelmeyi hedefler. SCNet'in genel mimarisi Şekil 4.12'de gösterilmiştir.




Şekil 4.12. SCNet genel mimarisi

4.4. Önerilen Hibrit Beyin Kanaması Tespit Yöntemi

Hibrit yöntemler, birden fazla yaklaşımı birleştiren ve genellikle daha etkin ve doğru sonuçlar elde etmek için kullanılan yöntemlerdir. Kendi başlarına kullanıldığında, her bir teknik belirli bir derecede başarı gösterebilir ancak çoğu durumda birleşik güçleri daha geniş bir kapsama alanı ve daha yüksek bir doğruluk seviyesi sağlar. Özellikle karmaşık problemler ve büyük veri kümeleri üzerinde çalışırken, hibrit yöntemlerin kullanılması genellikle daha etkili ve verimli sonuçlar verir. Tez kapsamında önerilen hibrit beyin kanaması tespit yöntemi, bölütleme ve sınıflandırma modeli olmak üzere iki ana bileşenden oluşmaktadır. Bu iki aşamalı süreç hem beyin kanaması tespitinin hem de sınıflandırılmasını gerçekleştirmektedir. Geliştirilen yöntem Şekil 4.13'de görsel olarak özetlenmiştir.

İlk aşamada, veri kümesinde DICOM formatlı olarak saklanan BT taramaları PNG formatına çevrilmiştir. Bu format dönüşümü ile veriler bölütleme modelinde işlenebilir hale getirilmiştir. Sonrasında tarama görüntüleri "sağlıklı" ve "kanamalı" olmak üzere iki gruba ayrılmıştır. Kanamalı olan taramalar %80 eğitim ve %20 test olacak şekilde bölümlendirilmiştir.



Şekil 4.13. Önerilen hibrit sistemin genel mimarisi

Eğitim için ayrılmış veri kümesi kullanılarak, MS R-CNN bölütleme modeli eğitilmiştir. Elde edilen model ile test kümesi içerisinde beyin kanamasının potansiyel belirtilerini içeren görüntüler tespit edilerek, bu alanların bir maske ve sınırlayıcı kutu ile işaretlenmesi sağlanmıştır. Modelin, herhangi bir kanama belirtisi tespit etmediği, taramalar "sağlıklı" olarak sınıflandırılmıştır. Ancak bölütleme modeli bazı durumlarda sağlıklı olduğu halde yanıltıcı belirtiler gösteren beyin bölgelerini yanlışlıkla "kanamalı" olarak işaretleyebilir. Bu tür yanıltıcı belirtilerin üstesinden gelmek amacıyla, ikinci bir kontrol mekanizması olarak EfficientNet-B2 sınıflandırma modelinden faydalanılmıştır. Bu model hibrit yöntemin ikinci aşamasını temsil etmektedir. İlk aşamada bölütleme modeli ile işaretlenen bölgeler, EfficientNet-B2 modeline yönlendirilmektedir. EfficientNet-B2 modeli girdi olarak aldığı sınırlayıcı kutu bölgelerini analiz ederek, bunların gerçekten bir beyin kanaması içerip içermediğini tespit etmektedir.

EfficientNet-B2 modelinin eğitim sürecinde, iki farklı kaynaktan veri kullanılmıştır. İlk girdi, bölütleme modelimizden elde edilen ve yanıltıcı belirtiler nedeniyle hatalı işaretlenmiş olan "sağlıklı" beyin taramalarının sınırlayıcı kutu bilgileridir. İkinci girdi ise, "kanamalı" olarak belirlenen beyin taramalarının eğitimde kullanılan kısmıdır. Bu taramalar da bölütleme modelinden geçirilmektedir. Model, taramaları analiz eder ve kanamalı bölgeleri sınırlayıcı kutularla işaretler. Bu kutular, gerçekten kanama olan bölgeleri temsil eder ve bu bilgiler de EfficientNet-B2 modelinin eğitimine girdi olarak dahil edilir. Bu iki tür veri, EfficientNet-B2 modelinin eğitim sürecinde kullanılır. Yanlış pozitifler, modelin sağlıklı beyin bölgelerini yanlışlıkla kanama olarak işaretlemesini önlemeye yardımcı olurken, gerçek kanamaları belirten sınırlayıcı kutular modelin kanamaları doğru bir şekilde tespit etme yeteneğini geliştirir. Bu çift yönlü yaklaşım, modelin hem hassasiyetini hem de doğruluğunu artırır.

4.5. Değerlendirme Ölçütleri

Bu kısımda çalışmada sınıflandırma ve bölütleme tekniklerinin performansını değerlendirmek için kullanılan ölçütlerden bahsedilmiştir. Sınıflandırma için eğitilen modellerin değerlendirilmesi amacıyla doğruluk, kesinlik, hassasiyet, F1 skor ve AUC (Eğri Altında Kalan Alan) metrikleri kullanılmıştır. Doğruluk, sınıflandırıcı tarafından doğru yapılan tahminlerin tüm tahminlere oranını, kesinlik, doğru tahin ettiğimiz kanamalı görüntülerin, tüm kanamalı tahminlerimize oranını, hassasiyet, doğru tahin

ettiğimiz kanamalı görüntülerin tüm kanamalı görüntülere oranını, F1 skor, kesinlik ve hassasiyet metriklerinin harmonik ortalamasını ve AUC, bir sınıflandırıcının sınıfları ayırt etme yeteneğinin bir ölçüsüdür ve yanlış pozitif oranı ile doğru pozitif oranı arasındaki ilişkiye dayanır. Yüksek bir AUC değeri, modelin sınıfları ayırt etme yeteneğinin daha iyi olduğunu gösterir. Metriklere ait formüller sırasıyla Eşitlik (4.1), (4.2), (4.3) ve (4.4)'te verilmiştir. Eşitliklerde gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif değerler sırasıyla TP, TN, FP ve FN olarak gösterilmektedir. TP değeri kanamalı olarak tahmin edilen ve gerçekte de kanama içeren görüntülerin sayısını, TN değeri kanamasız olarak tahmin edilen ve gerçekte de kanama içermeyen görüntülerin sayısını, FP değeri kanamalı olarak tahmin edilen ancak gerçekte kanama içermeyen görüntülerin sayısını ve FN değeri ise kanamasız olarak tahmin edilen ancak gerçekte kanamalı olan görüntülerin sayısını temsil etmektedir.

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (4.1)$$

$$\text{Kesinlik} = TP / (TP + FP) \quad (4.2)$$

$$\text{Hassasiyet} = TP / (TP + FN) \quad (4.3)$$

$$F1 \text{ skor} = 2 * \frac{\text{Kesinlik} * \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (4.4)$$

Bölütleme yöntemlerinin doğruluğunun tespiti için için örtüşme oranı (IoU) değeri eşik olarak kullanılmıştır. IoU, iki sınır arasındaki örtüşmeyi ölçer. Bu, algoritma tahmin edilen sınırın gerçekte (gerçek nesne sınırı) ne kadar örtüştüğünü ölçmek için kullanılır. Hesaplanışı Formül 4.5'te gösterilmiştir. Formüldeki A ve B, modelin ve temel gerçeğin çıktılarıdır. Bir görüntü bölütlemenin doğru veya yanlış olarak değerlendirilebilmesi için IOU kesişim oranının belirlenen bir eşik değerinden yüksek olması gerekir. Geleneksel olarak son teknoloji veri kümeleri, tahminin gerçek pozitif mi yoksa yanlış pozitif mi olduğunu sınıflandırmak için 0,5'e eşit veya daha büyük bir IoU eşiği kullanılır. Çalışmada IOU değeri 0,5 alınarak tespit ve bölütleme doğrulukları elde edilmiştir.

$$IOU = \frac{A \cap B}{A \cup B} \quad (4.5)$$

Tespit ve bölütleme doğruluklarının değerlendirilmesinde mAP ölçütü kullanılmıştır. Bu ölçüt algılanan sınırlayıcı kutuların kesinlik ve hassasiyet metriklerinin çarpımıdır. mAP, her sınıf (subdural kanama ve arka plan) için ayrı ayrı ortalama kesinlik (AP) hesaplanarak ve ardından sınıfların ortalaması alınarak elde edilmektedir. Bir tespit yalnızca IoU belirli bir eşiğin üzerindeyse gerçek bir pozitif olarak kabul edilir. Tüm görüntüler eşik değerine göre değerlendirildikten sonra hassasiyet-geri çağırma hesaplanabilir. Kesinlik, model tarafından üretilen doğru örneklerin toplam sayısını ifade eder ve aşağıdaki şekilde hesaplanır:

$$P = \frac{\text{True positive}}{\text{True positive} + \text{False positive}} \quad (4.6)$$

Modelin üretebileceği toplam pozitif tahmin sayısı, aşağıdaki şekilde hesaplanan bir geri çağırma ile ölçülür:

$$R = \frac{\text{True positive}}{\text{True positive} + \text{False negative}} \quad (4.7)$$

PR eğrisinin altındaki alan ortalama doğruluğu belirlemek için kullanılır. Formül (4.8) AP'nin hesaplanışını göstermektedir:

$$AP = \sum_{n=1}^N [R(n) - R(n - 1)] \cdot \max P(n) \quad (4.8)$$

N, belirlenen toplam PR noktası sayısıdır. mAP aşağıdaki denklem kullanılarak hesaplanır:

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (4.9)$$

AP_i i sınıfının ortalama hassasiyeti ve n sınıf sayısıdır.

5. DENEYSEL ÇALIŞMA

Tez çalışması kapsamında önerilen hibrit model SDH kanamaların hem tespitini hem de sınıflandırılmasını gerçekleştirmektedir. Dolayısıyla deneysel çalışmalar gerçekleştirilirken sırasıyla uygun sınıflandırma ve bölütleme yöntemlerinin seçimini gerçekleştirmiştir. Ardından bu modelleri bir araya getiren hibrit modelin başarısı değerlendirilmiştir. Bu akışa uygun olacak şekilde bu bölümde de ilk olarak, bazı yaygın kullanılan sınıflandırma ve bölütleme tekniklerinin probleme özgü veri kümeleri üzerinde uygulanmasıyla elde edilen sonuçlar verilmiştir. Daha sonra, tezde önerilen hibrit beyin kanaması tespit yönteminin sonuçları ve bu sonuçların literatürdeki benzer çalışmalarla karşılaştırması paylaşılmıştır.

Yöntemlerin geliştirilmesi ve uygulanması sırasında Intel Xeon 2.2GHz işlemci, 28 GB Ram ve 16 GB NVIDIA Tesla P100 GPU'ya sahip bir sunucu ve geliştirme dili olarak Python kullanılmıştır.

Literatürde beyin kanaması tespit problemi için sınırlı sayıda açık veri kümesi bulunmaktadır. Mevcut veri kümeleri içerisinde de bölütleme problemine uygun şekilde işaretlenmiş olan tek veri kümesi PhysioNet'dir. PhysioNet veri kümesi de alt kanama türleri göz önünde bulundurulduğunda sınırlı sayıda veriye sahiptir. Bu nedenle çalışma kapsamında beyin kanamalarının alt türlerinden, diğer veri kümelerine göre daha fazla sayıda veriye sahip CQ500 veri kümesi kullanılmıştır. Ancak bu veri kümesinde yer alan görüntüler de gerçek kanama noktalarına ait referans değerlerini (ground truth) içermemektedir.


Gerçek referans bölgelerinin elde edilmesi sürecinin zorluğu ve alt türlerin birbirlerinden farklı örüntülerde şekillere sahip olması gibi faktörler göz önünde bulundurularak tez çalışması kapsamında yalnızca bir alt kanama türüne odaklanılmıştır. Kanama türleri üzerindeki bölütleme çalışmaları incelendiğinde, subdural kanamanın diğerlerine göre daha zor bölütlendiği gözlenmiştir (Xu ve diğ., 2021). Bu alanda yapılan kısıtlı sayıdaki çalışmalar da göz önünde bulundurularak tez çalışması kapsamında SDH türündeki kanamalara odaklanılmıştır.

5.1. Sınıflandırma Sonuçları


Tez çalışması SDH kanamalarının tespiti ve sınıflandırılması amacıyla CQ500 veri kümesi kullanılarak gerçekleştirilmiştir. Ancak önerilen hibrit modelde kullanılacak sınıflandırma algoritmasının seçiminde karşılaştırmalar hem CQ500 hem de PhysioNet veri kümeleri kullanılarak yapılmıştır. Böylece sınıflandırma algoritmasının seçiminde veri kümesinden bağımsız probleme özgü olarak en başarılı sonuçları veren en uygun modelin seçilmesi amaçlanmıştır.

Sınıflandırma açısından en yüksek performansa sahip model, önerilen hibrit modelin iyileştirme sürecinde kullanılacağından sınıflandırıcı seçimi önem arz etmektedir. Model eğitimi öncesi veri kümeleri %80 eğitim %20 test olacak şekilde bölümlenmiştir. Eğitim için VGG modellerinden VGG-11, VGG-13 ve VGG-16, ResNet modellerinden ResNet-50 ve ResNet-101 ve EfficientNet modellerinden de EfficientNet-B0, EfficientNet-B1, EfficientNet-B2 ve EfficientNet-B3 kullanılmıştır. Modellere ait PhysioNet veri kümesi üzerinden elde edilen doğruluk değerleri Şekil 5.1’de, CQ500 veri kümesi üzerinden elde edilen doğruluk değerleri ise Şekil 5.2’de gösterilmiştir.


Grafikler incelendiğinde en yüksek doğruluk oranının EfficientNet-B2 modeli ile elde edildiği görülmektedir. VGG, ResNet ve EfficientNet modelleri kendi içlerinde incelendiğinde modellerin karmaşıklığındaki artışın doğruluk oranını düşürdüğü gözlemlenmiştir. Bu durum problemin karmaşıklığına uygun model seçiminin derin öğrenmedeki önemini göstermektedir. BT görüntüleri üzerinden gerçekleştirilen ikili sınıflandırma problemi (kanama var/yok) için karmaşıklığı düşük modeller daha yüksek doğruluk değeri vermiştir. Elde edilen sonuçlar modelin probleme özgü olarak seçilmesi gerektiğinin açık bir göstergesidir. Sınıf etiketlerinde var olan dengesiz dağılım sebebiyle doğruluk değerine ek olarak F1 skor değeri de hesaplanmıştır. PhysioNet ve CQ500 veri kümelerinin her biri için F1 skor değerine ait sonuçlar sırasıyla Şekil 5.3 ve Şekil 5.4’de gösterilmiştir. EfficientNet-B2 modelinin yüksek doğruluk oranının yanı sıra, F1 skorları da oldukça etkileyici olduğundan, bu model hibrit modelin sınıflandırıcı parçası olarak seçilmiştir. Sonuç olarak, veriye ve probleme özgü derin öğrenme modeli seçiminin, bilgisayarlı görü sağlık uygulamalarında başarı için kritik olduğu tekrar vurgulanmıştır.




Şekil 5.1. PhysioNet veri kümesinde sınıflandırma modellerinden elde edilen doğruluk değerleri



Şekil 5.2 PhysioNet veri kümesinde sınıflandırma modellerinden elde edilen f1 skor değerleri



Şekil 5.3. CQ500 veri kümesinde sınıflandırma modellerinden elde edilen doğruluk değerleri



Şekil 5.4. CQ500 veri kümesinde sınıflandırma modellerinden elde edilen f1 skor değerleri

Şekil 5.2 ve Şekil 5.4 incelendiğinde görüldüğü üzere VGG ve ResNet mimarileri için ağın karmaşıklığı yükseldiğinde model aşırı öğrenme eğilimine girmektedir. EfficientNet modellerinde de benzer durum söz konusudur ancak bu modellerde karmaşıklığın artışı ile F1 skor değerindeki düşüş oranı VGG ve ResNet modelleri kadar yüksek değildir. Bu da bize EfficientNet modellerinin aşırı öğrenmeye karşı diğerlerinden daha dayanıklı olduğunu göstermektedir.

Tablo 5.1. PhysioNet veri kümesi sınıflandırma modellerinden elde edilen sınıflandırma sonuçları

Yöntem	Doğruluk	Kesinlik	Hassasiyet	F1 Skor
VGG-11	95,9147	90,5085	88,8417	89,6511
VGG-13	89,1652	72,9331	62,5595	65,5927
VGG-16	94,3162	85,8968	85,8968	85,8968
ResNet-50	95,5595	89,5892	87,9603	88,7512
ResNet-101	90,9414	82,1807	65,6046	70,1121
EfficientNet-B0	97,1581	94,6005	90,9052	92,6458
EfficientNet-B1	96,6252	93,4523	89,2425	91,2035
EfficientNet-B2	97,3357	95,4043	91,0054	93,0554
EfficientNet-B3	96,0924	94,2456	85,5367	89,2639

Çalışma kapsamında değerlendirilen tüm metriklerin sonuçları detaylı olarak Tablo 5.1 ve Tablo 5.2’de verilmiştir. Tablolar üzerinden genel bir değerlendirme yapıldığında, EfficientNet-B2 modelinin BT görüntüler kullanılarak beyin kanamalarının

sınıflandırılması problemi için değerlendirilen modeller arasından en uygun model olduğu görülmektedir.

Tablo 5.2. CQ500 veri kümesi sınıflandırma modellerinden elde edilen sınıflandırma sonuçları

Yöntem	Doğruluk	Kesinlik	Hassasiyet	F1 Skor
VGG-11	83,9662	85,1361	85,5198	83,9591
VGG-13	81,8565	82,6584	83,172	81,8358
VGG-16	88,785	88,8277	89,101	88,7693
ResNet-50	88,5965	84,2014	78,237	80,6704
ResNet-101	83,9662	83,5748	83,7362	83,6492
EfficientNet-B0	85,2321	85,843	86,4953	85,2057
EfficientNet-B1	81,0127	81,6066	82,1819	80,9788
EfficientNet-B2	88,7850	88,7491	89,0218	88,7605
EfficientNet-B3	81,8565	82,8828	83,2994	81,8449

5.2. Bölütleme Sonuçları

Önerilen hibrit modelin ilk aşamasında bölütleme işlemi gerçekleştirilmektedir. Dolayısıyla seçilecek bölütleme algoritmasının doğruluğu hibrit modelinde doğruluğu üzerinde ciddi etkiye sahiptir. Bu amaçla literatürde yer alan bölütleme algoritmalarından yaygın kullanılan Mask R-CNN, Cascade R-CNN, MS R-CNN, HTC, YOLACT ve SCNet algoritmalarının başarısı SDH kanamalarının tespiti açısından karşılaştırılmıştır. Karşılaştırmalar CQ500 veri kümesi kullanılarak gerçekleştirilmiştir. Daha önce de bahsedildiği gibi bu veri kümesi kanamalar için bölütleme işaretlemelerine sahip değildir. Bu nedenle ilk olarak yeterli sayıda SDH tarama görüntüsü bir Beyin ve Sinir Cerrahisi Uzmanı (Dr. Öğr. Üyesi İsmail KAYA) tarafından işaretlenmiştir. Model eğitimi öncesi veri kümesi %80 eğitim %20 test olacak şekilde bölümlenmiştir.

Kullanılan metotların mimari detayları Tablo 5.3'de verilmiştir. Tabloda, LR kısaltması metotlar için Öğrenme Oranı değerini temsil etmektedir. Literatürde, SGD (Stokastik Gradyan İnişi) için, 0,02 ve 0,002 arasında bir LR değerinin, geleneksel 0,1 ve 0,0001 arası değerlerden daha iyi sonuçlar verdiği ifade edilmiştir (Zhang ve diğ., 2020). Bu nedenle, Adam optimizasyon fonksiyonunu kullanan QueryInst yöntemi ve kendi

makalesinde LR değeri 0,001 olarak belirtilen YOLACT yöntemi dışında, LR değeri 0,02 olarak alınmıştır.

Tablo 5.4’te sekiz farklı mimari için elde edilen doğruluk değerleri listelenmiştir.

Tablo 5.3 Bölütleme modellerinin genel mimarisi

Yöntem	Omurga	Boyun	Head	Opt.	LR
Mask R-CNN 50	ResNet-50	FPN-RPN	FCBBoxHead FCNMaskHead	SGD	0,02
Mask R-CNN 101	ResNet-101	FPN-RPN	FCBBoxHead FCNMaskHead	SGD	0,02
Cascade R-CNN	ResNet-50	FPN-RPN	3*FCBBoxHead FCNMaskHead	SGD	0,02
MS R-CNN	ResNet-101	FPN-RPN	FCBBoxHead FCNMaskHead	SGD	0,02
HTC	ResNet-50	FPN-RPN	3*(FCBBoxHead HTCMaskHead)	SGD	0,02
YOLACT	ResNet-50	FPN	YOLACTHead YOLACTProtonet	SGD	0,001
QueryInst	ResNet-50	FPN-RPN	SparseRoIHead 6*(DIIHead- DynamicMaskHead)	Adam	0,0001
SCNet	ResNet-50	FPN-RPN	3*SCNetBBoxHead SCNetMaskHead GlobalContextHead	SGD	0,02

Tablo 5.4 Bölütleme modellerinin doğruluk değerleri

Yöntem	Sınırlayıcı kutu mAP 50	Maske mAP 50
Mask R-CNN 50	0,8540	0,7960
Mask R-CNN 101	0,7930	0,7840
Cascade R-CNN	0,8470	0,8270
MS R-CNN	0,8670	0,8780
HTC	0,8520	0,8250
YOLACT	0,8490	0,8590
QueryInst	0,7770	0,8090
SCNet	0,8710	0,8080


Bu çalışmada kullanılan görüntüler, bölütlenmesi gereken kanama bölgelerinin arka plan beyin dokusu ile benzer doku özelliklerine sahip olması ve çok küçük boyutta ve düzensiz şekilli olması nedeniyle bölütleme açısından zorlayıcıdır. Problemin zorluğuna rağmen seçilen her bir yöntem, tespit ve bölütleme değeri açısından %78'den fazla bir doğruluk oranına sahiptir. Yöntemler karşılaştırıldığında kanamalı bölgenin tespiti açısından en başarılı yöntem SCNet olurken bölütleme açısından en başarılı yöntem MS R-CNN olmuştur. Her iki kriter açısından değerlendirildiğinde ise en yüksek başarı MS R-CNN yöntemi ile elde edilmiştir.

5.3. Hibrit Model Sonuçları

Bu bölümde, tez kapsamında geliştirilen hibrit yöntemin sonuçları açıklanmıştır. Hibrit modelin değerlendirilmesinde hem tespit hem de sınıflandırma problemine uygun olması sebebiyle CQ500 veri kümesi kullanılmıştır.


Veri kümesinin bölünmesi sürecinde hasta bazlı ve rastgele olmak üzere iki farklı teknik kullanılmıştır. Hasta bazlı bölümlenme de bir hastanın tüm görüntüleri ya eğitim kümesine ya da test kümesine dahil edilerek model eğitim ve test süreci tamamlanmaktadır. Bu yaklaşımın temel amacı, modelin aynı hastanın farklı görüntülerini görerek yanıltıcı bir şekilde yüksek performans göstermesini engellemektir. Hasta bazlı bölümlenme, modelin gerçek dünya durumlarında ne kadar iyi genelleştirebileceğini daha iyi anlamamıza yardımcı olmaktadır.

Rastgele bölümlenme tekniğinde veri kümesindeki görüntüler rastgele eğitim ve test kümelerine dağıtılmaktadır. Bu durumda, aynı hastanın görüntüleri hem eğitim hem de test kümelerinde bulunabilmektedir. Bu yöntem genellikle modelin genel performansını değerlendirmek için daha hızlı bir yol olarak tercih edilmektedir. Ancak, bu yaklaşımın dezavantajı, aynı hastanın görüntülerinin hem eğitim hem de test kümelerinde bulunması nedeniyle modelin performansının yanıltıcı olabilmesidir. Literatürde her iki yaklaşımla veri bölümlenmesini gerçekleştiren çalışmalar mevcuttur. Şekil 5.5’de sadece sınıflandırıcı model, yani görüntülerin bölütleme sürecinden geçmeden doğrudan sınıflandırma algoritmasına tabi tutulduğunda elde edilen sonuçları göstermektedir.



Şekil 5.5. Sadece Sınıflandırıcı Model ile Elde Edilen Sonuçlar

Hasta bazlı ayrıştırmada, modelin doğruluk oranı %88,785, kesinlik oranı %84,9056, hassasiyeti %91,8367 ve F1 skoru %88,2352 olarak tespit edilmiştir. Bu sonuçlar, modelin genel olarak iyi bir performans gösterdiğini ve doğru tahminler yapabildiğini göstermektedir. Rastgele ayrıştırma yönteminde ise, modelin performansı daha da artmıştır. Doğruluk oranı %91,7098, kesinlik oranı %88,172, hassasiyeti %94,2528 ve F1 skoru %91,11 olarak ölçülmüştür. Bu sonuçlar, modelin rastgele ayrıştırılmış veri kümesinde daha yüksek bir genel performans sergilediğini göstermektedir.




Şekil 5.6. Sadece Sınıflandırıcı Modeller ile Elde Edilen Karmaşıklık Matrisleri

Genel olarak, her iki ayrıştırma yönteminde de modelin yüksek bir performans gösterdiği ve beyin kanamalarını etkin bir şekilde sınıflandırabildiği görülmektedir. Ancak, modelin rastgele ayrıştırılmış veri kümesinde daha yüksek performans sergilediği görülmektedir.


Bu durum, modelin belirli hastalardan öğrenilen bilgileri genelleştirme yeteneğinin hasta bazlı ayrıştırma yönteminde biraz daha sınırlı olabileceğini göstermektedir.

Şekil 5.7’de ise geliştirilen hibrit yöntemden elde edilen sonuçlar gösterilmiştir. Hasta bazlı ayrıştırmada modelin doğruluk oranı %91,5888, kesinlik oranı %89,2157, hassasiyeti %92,8571 ve F1 skoru %91,55 olarak ölçülmüştür. Modelin hassasiyet ve doğruluk oranlarının birbirine çok yakın olduğu görülmektedir. Bu da modelin hem pozitif (kanama olan) hem de negatif (kanama olmayan) örnekleri doğru bir şekilde tahmin edebildiğini göstermektedir.



Şekil 5.7. Hibrit Model ile Elde Edilen Sınıflandırma Sonuçları

Rastgele ayrıştırmada ise, modelin performansı daha da artmıştır. Doğruluk oranı %94,3005, kesinlik oranı %90,4255, hassasiyeti %97,7011 ve F1 skoru %93,9227 olarak ölçülmüştür. Bu sonuçlar, modelin rastgele ayrıştırılmış veri kümesinde daha yüksek bir genel performans sergilediğini göstermektedir. Tablo 5.5’te literatürde CQ500 veri kümesi kullanılarak gerçekleştirilmiş olan çalışmalarla önerilen yöntemin karşılaştırması verilmiştir. Literatürde CQ500 veri kümesi üzerinden SDH kanamaların bölütlenmesini gerçekleştiren bir çalışma mevcut değildir. Bu nedenle tabloda yer alan karşılaştırma sonuçları önerilen modelin nihai sınıflandırma başarısını içermektedir.



Şekil 5.8. Hibrit Model ile Elde Edilen Karmaşıklık Matrisleri

Tablo 5.5. Hibrit Yöntemin Literatür ile Karşılaştırılması

Yöntem	Doğruluk	AUC	Bölümleme Şekli
Hibrit Model (Hasta Bazlı)	91,5888	92,9200	Hasta bazlı
Hibrit Model (Rastgele)	94,3005	96,9200	Rastgele
(Nguyen ve diğ., 2020)	-	96,5400	-
(López-Pérez ve diğ., 2022)	71,7000	90,9000	Hasta bazlı
(Chilamkurthy ve diğ., 2018)	-	94,0000	-
(Asif ve diğ., 2023)*	96,2000	-	-
(Kumaravel ve diğ., 2021)*	99,8600	-	Rastgele
(Lin ve diğ., 2021)*	-	93,9000	Rastgele

Literatürdeki benzer çalışmalara bakıldığında, Kumaravel ve diğ., (2021) tarafından gerçekleştirilen çalışma ile en yüksek doğruluk oranı (%99,86) elde edilmiştir, ancak azaltılmış bir veri kümesi üzerinde çalışıldığı için sonuçları tam anlamı ile karşılaştırılabilir değildir. Asif ve diğ. (2023) ile Lin ve diğ. (2021), CQ500 veri kümesini sadece doğrulama için kullanmışlar ve geniş kapsamlı veri kümeleriyle eğitim yapmışlardır. Bu çalışmalara rağmen, modelimiz Asif ve diğ. (2023) ile benzer başarı oranı (%96,2) sağlarken, Kumaravel ve diğ. (2021) çalışması (AUC değerinde %86) modelimizden daha düşük performans göstermiştir. Tez kapsamında önerilen model ile kıyaslandığında, AUC metriği esas alınan çalışmalardan daha üstün bir performans sergilemiştir.

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, beyin kanamalarının tespiti ve sınıflandırılması için hibrit bir model geliştirilmiştir. Bu model bölütleme ve sınıflandırma olmak üzere iki aşamalı bir süreçte sahiptir. İlk aşamada, MS R-CNN modeli, taramaları "kanamalı" ve "sağlıklı" olarak bölütlenmektedir. Ancak, bölütleme modeli bazen sağlıklı beyin bölgelerini yanlışlıkla belirtiler nedeniyle "kanamalı" olarak işaretleyebilmektedir. Bu durumu düzeltmek için, ikinci aşamada, EfficientNet-B2 modeli ile iki seviyeli doğrulama sağlanmaktadır. Bölütlenen bölgelerin gerçekten beyin kanaması içerip içermediği belirlenmektedir.

Tez çalışmasının ana katkıları aşağıdaki gibi maddeler halinde sıralanabilir:

- Literatürde SDH kanamalarının bölütlenmesi amacıyla işaretlenmiş yeterli sayıda BT taramalarını içeren bir veri kümesi mevcut değildir. Bu tez çalışması ile CQ500 veri kümesinde yer alan SDH türündeki kanamaların bir uzman tarafından işaretlenmesi sağlanmıştır. Elde edilen işaretli veri kümesi özellikle SDH kanamaların bölütlenmesi ve sınıflandırılması çalışmalarında kullanılabilecek değerli bir kaynaktır.
- Beyin kanamalarının sınıflandırılması ve bölütlenmesi için kullanılabilecek literatürdeki güncel model ve mimariler belirlenmiş, bu yöntemlere ait karşılaştırmalı sonuçlar ayrı ayrı elde edilmiştir. Elde edilen sonuçlar bu alanda gerçekleştirilecek çalışmalara temel oluşturacak niteliktedir.
- Önerilen hibrit modelin sonuçları hem hasta bazlı ve hem de rastgele bölümlerle teknikleriyle elde edilmiştir. Böylece, modelin genelleme yeteneği ve her iki bölümlerle tekniğine nasıl yanıt verdiği açık bir şekilde ifade edilmiştir.
- Bu alanda gerçekleştirilen çalışmalar incelendiğinde sınıflandırma işlemini iki aşamalı olarak bölütlenen bölge üzerinden gerçekleştiren bir çalışma ile karşılaşılmamıştır.
- Hibrit modelin performansı, literatürdeki benzer çalışmalarla karşılaştırıldığında, sınıflandırma başarısı açısından aynı veri kümesi üzerinde gerçekleştirilen çalışmalardan daha başarılı olduğu tespit edilmiştir.

Tez kapsamında geliştirilen hibrit modelin en önemli eksikliği hasta bazlı bölümlerle tekniği kullanıldığında, aynı hastadan gelen verilerin genellemesinin bir miktar sınırlı

kalmasıdır. Bu noktada modelin genelleme kabiliyetinin geliştirilmesi gerekmektedir. Eğitim sürecinde daha fazla ve çeşitli veri kümelerinin kullanılması, modelin genelleme yeteneğini artırabilir ve performansını daha da geliştirebilir. Model bazı sağlıklı BT taramalarını kanama olarak işaretlemiştir. Bu yanlış işaretlemeler bir beyin cerrahı tarafından yorumlanmıştır. İnceleme sonucunda modelin damar gölgelerini, beyin ve kafatası yapısındaki normal varyasyonları ve bazı görüntülerde belirgin olan orta çizgiyi yanlışlıkla kanama belirtisi olarak algıladığını ortaya koyulmuştur. Ayrıca, modelin beyin görüntüsü olmayan, boyun omurgasına ait bazı görüntülerde kanama tespit etmesi, yanlış pozitif sonuçların nedenleri olarak gösterilebilir. Bu gözlemler, modelin hassasiyetini artırmak için gerekli olan iyileştirmelerin belirlenmesinde yardımcı olacak kıymetli bilgiler sunuyor.

Aynı zamanda mevcut model, DICOM formatındaki verileri PNG formatına çevirerek ve RGB verilerini işleyerek çalışır. Bu süreç, DICOM formatındaki bazı bilgilerin, özellikle Hounsfield birim değerlerinin kaybolmasına neden olabilir. Bu değerler, dokuların yoğunluğuna dair önemli bilgiler sağlar ve beyin kanamalarının tespitinde kullanılabilir.

Bu çalışmanın devamında Hounsfield değerlerini de işleyebilen bir mimari geliştirilebilir. Modelin genel performansını ve uygulanabilirliğini artırmak için, farklı demografik gruplardan ve farklı tıbbi cihazlardan elde edilen verilere dayanan daha geniş ve çeşitli veri kümeleri üzerinde eğitimler gerçekleştirilebilir.

KAYNAKLAR

- Anupama, C.S.S., Sivaram, M., Lydia, E.L., Gupta, D., Shankar, K. (2022). Synergic Deep Learning Model–Based Automated Detection And Classification of Brain Intracranial Hemorrhage Images in Wearable Networks. *Personal and Ubiquitous Computing*, 26(1), 1-10.
- Asif, M., Shah, M.A., Khattak, H.A., Mussadiq, S., Ahmed, E., Nasr, E.A., Rauf, H.T. (2023). Intracranial Hemorrhage Detection Using Parallel Deep Convolutional Models and Boosting Mechanism. *Diagnostics*, 13(4), 652.
- Bercovich, E., Javitt, M.C. (2018). Medical Imaging: From Roentgen to the Digital Revolution, and Beyond. *Rambam Maimonides Medical Journal*, 9(4), e0034.
- Bhadauria, N.S., Kumar, I., Bhadauria, H.S., Patel, R.B. (2021). Hemorrhage Detection Using Edge-Based Contour with Fuzzy Clustering from Brain Computed Tomography Images. *International Journal of System Assurance Engineering and Management*, 12(6), 1296-1307.
- Bolya, D., Zhou, C., Xiao, F., Lee, Y.J. (2019). Yolact: Real-time Instance Segmentation. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Seoul, Korea, 27 Ekim-2 Kasım 2019
- Burduja, M., Ionescu, R.T., Verga, N. (2020). Accurate and Efficient Intracranial Hemorrhage Detection and Subtype Classification in 3D CT Scans with Convolutional and Long Short-Term Memory Neural Networks. *Sensors*, 20(19), 5611.
- Cai, Z., Vasconcelos, N. (2019). Cascade R-CNN: High Quality Object Detection and Instance Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(5), 1483-1498.
- Chen, H., Khan, S., Kou, B., Nazir, S., Liu, W., Hussain, A. (2020). A Smart Machine Learning Model for the Detection of Brain Hemorrhage Diagnosis Based Internet of Things in Smart Cities. *Complexity*, 2020, e3047869.
- Chen, K., Pang, J., Wang, J., Xiong, Y., Li, X., Sun, S., Ouyang, W. (2019). Hybrid Task Cascade for Instance Segmentation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seoul, Korea, 27 Ekim-2 Kasım 2019
- Chilamkurthy, S., Ghosh, R., Tanamala, S., Biviji, M., Campeau, N.G., Venugopal, V.K., Warier, P. (2018). Deep Learning Algorithms for Detection of Critical Findings in Head CT Scans: A Retrospective Study. *The Lancet*, 392(10162), 2388-2396.
- Cortés-Ferre, L., Gutiérrez-Naranjo, M.A., Egea-Guerrero, J.J., Pérez-Sánchez, S., Balcerzyk, M. (2023). Deep Learning Applied to Intracranial Hemorrhage Detection. *Journal of Imaging*, 9(2), 37.

- Fang, Y., Yang, S., Wang, X., Li, Y., Fang, C., Shan, Y., Liu, W. (2021). Instances as Queries. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, Online, 11-17 Ekim 2021
- Farzaneh, N., Williamson, C.A., Jiang, C., Srinivasan, A., Bapuraj, J.R., Gryak, J., Najarian, K., Soroushmehr, S. M.R. (2020). Automated Segmentation and Severity Analysis of Subdural Hematoma for Patients with Traumatic Brain Injuries. *Diagnostics*, 10(10), 773.
- Gençtürk, T.H., GÜLAĞIZ, F.K., İsmail, K. (2023). Derin Öğrenme Yöntemleri Kullanılarak BT Taramalarında Beyin Kanaması Teşhisinin Karşılaştırmalı Bir Analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(1), 75-84.
- Gençtürk, T.H., Kaya, İ., Gülağız, F.K. (2023). A Comparative Study on Subdural Brain Hemorrhage Segmentation. *Computational Intelligence, Data Analytics and Applications: Selected papers from the International Conference on Computing, Intelligence and Data Analytics*, Kocaeli, Türkiye, 16-17 Eylül 2022
- Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*, Santiago, Şili, 7-13 Aralık 2015
- Gorgolewski, K.J., Auer, T., Calhoun, V.D., Craddock, R.C., Das, S., Duff, E.P., Poldrack, R.A. (2016). The Brain Imaging Data Structure: A Format for Organizing and Describing Outputs of Neuroimaging Experiments. *Scientific Data*, 3(1), 160044.
- He, K., Gkioxari, G., Dollár, P., Girshick, R. (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*, Venice, İtalya, 22-29 Ekim 2017
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, USA, 27-30 Haziran 2016
- Hori, K., Fujimoto, T., Kawanishi, K. (1998). Development of Ultra-Fast X-ray Computed Tomography Scanner System. *IEEE Transactions on Nuclear Science*, 45(4), 2089-2094.
- Hssayeni, M.D., Croock, M.S., Salman, A.D., Al-khafaji, H. F., Yahya, Z.A., Ghoraani, B. (2020). Intracranial Hemorrhage Segmentation Using a Deep Convolutional Model. *Data*, 5(1), 14.
- Huang, Z., Huang, L., Gong, Y., Huang, C., Wang, X. (2019). Mask Scoring R-CNN. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Seoul, Kore, 27 Ekim-2 Kasım 2019.

- Inkeaw, P., Angkurawaranon, S., Khumrin, P., Inmutto, N., Traisathit, P., Chaijaruwanich, J., Chitapanarux, I. (2022). Automatic Hemorrhage Segmentation on Head CT Scan for Traumatic Brain Injury Using 3D Deep Learning Model. *Computers in Biology and Medicine*, 146, 105530.
- Karki, M., Cho, J., Lee, E., Hahm, M.-H., Yoon, S.-Y., Kim, M., Ahn, Y.-J., Son, J., Park, H.-S., Kim, H.-K., Park, S. (2020). CT Window Trainable Neural Network for Improving Intracranial Hemorrhage Detection by Combining Multiple Settings. *Artificial Intelligence in Medicine*, 106, 101850.
- Kaya, İ., Gençtürk, T.H., & Gülağız, F.K. (2023). A Revolutionary Acute Subdural Hematoma Detection Based on Two-Tiered Artificial Intelligence Model. *Ulusal Travma ve Acil Cerrahi Dergisi*, 29(8). DOI: 10.14744/tjtes.2023.76756
- Kumar, I., Bhatt, C., Singh, K.U. (2022). Entropy-Based Automatic Unsupervised Brain Intracranial Hemorrhage Segmentation Using CT Images. *Journal of King Saud University - Computer and Information Sciences*, 34(6, Part A), 2589-2600.
- Kumaravel, P., Mohan, S., Arivudaiyanambi, J., Shajil, N., Venkatakrishnan, H.N. (2021). A Simplified Framework for the Detection of Intracranial Hemorrhage in CT Brain Images Using Deep Learning. *Current Medical Imaging*, 17(10), 1226-1236.
- Kuno, H., Sekiya, K., Chapman, M.N., Sakai, O. (2017). Miscellaneous and Emerging Applications of Dual-Energy Computed Tomography for the Evaluation of Intracranial Pathology. *Neuroimaging Clinics of North America*, 27(3), 411-427.
- Kurzweil, R., Richter, R., Kurzweil, R., Schneider, M. L. (1990). *The Age of Intelligent Machines* (C. 580). Cambridge: MIT Press.
- Larobina, M., Murino, L. (2014). Medical Image File Formats. *Journal of Digital Imaging*, 27(2), 200-206.
- Le, T., Bhushan, V., Qiu, C., Chalise, A., & Kaparaliotis, P. (2023). First Aid for the USMLE Step 1 2023 (33. Basım). McGraw Hill.
- Li, X., Luo, G., Wang, W., Wang, K., Gao, Y., Li, S. (2022). Hematoma Expansion Context Guided Intracranial Hemorrhage Segmentation and Uncertainty Estimation. *IEEE Journal of Biomedical and Health Informatics*, 26(3), 1140-1151.
- Lin, E., Kuo, W., Yuh, E. 2021. *Noisy Student Learning for Cross-Institution Brain Hemorrhage Detection*, ArXiv, <https://arxiv.org/abs/2105.00582>, (Ziyaret tarihi: 17 Nisan 2023).
- López-Pérez, M., Schmidt, A., Wu, Y., Molina, R., Katsaggelos, A.K. (2022). Deep Gaussian Processes for Multiple Instance Learning: Application to CT Intracranial Hemorrhage Detection. *Computer Methods and Programs in Biomedicine*, 219, 106783.

- Nguyen, N.T., Tran, D. Q., Nguyen, N.T., Nguyen, H.Q. (2020). A CNN-LSTM Architecture for Detection of Intracranial Hemorrhage on CT Scans. *MedRxiv*, 2020-04.
- Ozaltin, O., Coskun, O., Yeniay, O., Subasi, A. (2023). Classification of Brain Hemorrhage Computed Tomography Images using OzNet Hybrid Algorithm. *International Journal of Imaging Systems and Technology*, 33(1), 69-91.
- Pai, K. M. (2022). Region Detection and Segmentation of Brain Hemorrhage using Algorithmic Approach of Image Processing. *Journal of Physics: Conference Series*, 2161(1), 012070.
- Phan, A.-C., Cao, H.-P., Trieu, T.-N., Phan, T.-C. (2020). Detection and Classification of Brain Hemorrhage Using Hounsfield Unit and Deep Learning Techniques. *Future Data and Security Engineering. Big Data, Security and Privacy, Smart City and Industry 4.0 Applications* (281-293). Singapore: Springer.
- Phan, A.-C., Tran, H.-D., Phan, T.-C. (2021). Efficient Brain Hemorrhage Detection on 3D CT Scans with Deep Neural Network. *Future Data and Security Engineering: 8th International Conference, FDSE 2021, Virtual Event, 24-26 Kasım 2021*.
- Rawat, W., Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352-2449.
- Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *Advances in Neural Information Processing Systems*, 28.
- Richmond, C. (2004). Sir Godfrey Hounsfield. *BMJ: British Medical Journal*, 329(7467), 687.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Maryland: IEEE Computer Society.
- Santhoshkumar, S., Varadarajan, V., Gavaskar, S., Amalraj, J.J., Sumathi, A. (2021). Machine Learning Model for Intracranial Hemorrhage Diagnosis and Classification. *Electronics*, 10(21), 2574.
- Simonyan, K., Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*, ArXiv, <https://arxiv.org/abs/1409.1556>, (Ziyaret tarihi: 05 Nisan 2023).
- Singh, S. P., Wang, L., Gupta, S., Gulyás, B., Padmanabhan, P. (2021). Shallow 3D CNN for Detecting Acute Brain Hemorrhage From Medical Imaging Sensors. *IEEE Sensors Journal*, 21(13), 14290-14299.

- Solorio-Ramírez, J.-L., Saldana-Perez, M., Lytras, M. D., Moreno-Ibarra, M.-A., Yáñez-Márquez, C. (2021). Brain Hemorrhage Classification in CT Scan Images Using Minimalist Machine Learning. *Diagnostics*, 11(8), 1449.
- Subaiya, S., Roberts, I., Komolafe, E., Perel, P. (2012). Predicting Intracranial Hemorrhage After Traumatic Brain Injury in Low and Middle-Income Countries: A Prognostic Model Based on a Large, Multi-Center, International Cohort. *BMC Emergency Medicine*, 12(1), 17.
- Sun, P., Zhang, R., Jiang, Y., Kong, T., Xu, C., Zhan, W., Tomizuka, M., Li, L., Yuan, Z., Wang, C., Luo, P. (2021). Sparse R-CNN: End-to-End Object Detection With Learnable Proposals. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Maryland: IEEE Computer Society.
- Tan, M., Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *International Conference on Machine Learning*, Long Beach, USA, 9-15 Haziran, 2019.
- Tenny, S., Thorell, W. (2023). Intracranial Hemorrhage. *StatPearls*. Treasure Island (FL): StatPearls Publishing.
- Tu, W., Kong, L., Karunamuni, R., Butcher, K., Zheng, L., McCourt, R. (2019). Nonlocal Spatial Clustering in Automated Brain Hematoma and Edema Segmentation. *Applied Stochastic Models in Business and Industry*, 35(2), 321-329.
- URL-1: <https://www.saglik.gov.tr/TR,84966/saglik-istatistikleri-yilligi-2019-yayinlanmistir.html/>, (Ziyaret tarihi: 12 Mart 2022).
- Vu, T., Kang, H., Yoo, C.D. (2021). SCNet: Training Inference Sample Consistency for Instance Segmentation. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(3), 2701-2709.
- Wang, D., Wang, C., Masters, L., Barnett, M. (2020). Masked Multi-task Network for Case-level Intracranial Hemorrhage Classification in Brain CT Volumes. Medical Image Computing and Computer Assisted Intervention--MICCAI 2020: 23rd International Conference, Lima, Peru, 4-8 Ekim 2020.
- Xu, J., Zhang, R., Zhou, Z., Wu, C., Gong, Q., Zhang, H., Ma, J. (2021). Deep Network for the Automatic Segmentation and Quantification of Intracranial Hemorrhage on CT. *Frontiers in Neuroscience*, 14, 541817.
- Yao, H., Williamson, C., Gryak, J., Najarian, K. (2019). Brain Hematoma Segmentation Using Active Learning and an Active Contour Model. Bioinformatics and Biomedical Engineering: 7th International Work-Conference, IWBBIO 2019, Granada, İspanya, 8-10 Mayıs 2019.

- Yao, H., Williamson, C., Gryak, J., Najarian, K. (2020). Automated Hematoma Segmentation and Outcome Prediction for Patients with Traumatic Brain Injury. *Artificial Intelligence in Medicine*, 107, 101910.
- Yeo, M., Tahayori, B., Kok, H.K., Maingard, J., Kutaiba, N., Russell, J., Thijs, V., Jhamb, A., Chandra, V.R., Brooks, M., Barras, D.C., Asadi, H. (2021). Review of Deep Learning Algorithms for the Automatic Detection of Intracranial Hemorrhages on Computed Tomography Head Imaging. *Journal of Neurointerventional Surgery*, 13(4), 369-378.
- Yu, H.S., Gupta, A., Soto, J. A., LeBedis, C. (2016). Emergency Abdominal MRI: Current Uses and Trends. *The British Journal of Radiology*, 89(1061), 20150804.
- Zhang, G., Chen, K., Xu, S., Cho, P.C., Nan, Y., Zhou, X., Xie, G. (2021). Lesion Synthesis to Improve Intracranial Hemorrhage Detection and Classification for CT Images. *Computerized Medical Imaging and Graphics*, 90, 101929.
- Zhang, H., Wang, Y., Dayoub, F., Sünderhauf, N. (2020). *Swa Object Detection*, <https://arxiv.org/abs/2012.12645>, (Ziyaret tarihi: 02 Nisan 2023).
- Zhang, L., Miao, W., Zhu, C., Wang, Y., Luo, Y., Song, R., Liu, L., Yang, J. (2023). A Weakly Supervised-Guided Soft Attention Network for Classification of Intracranial Hemorrhage. *IEEE Transactions on Cognitive and Developmental Systems*, 15(1), 42-53.

KİŞİSEL YAYIN VE ESERLER

Gençtürk, T.H., Gülağız, F.K., İsmail, K. (2023). Derin Öğrenme Yöntemleri Kullanılarak BT Taramalarında Beyin Kanaması Teşhisinin Karşılaştırmalı Bir Analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(1), 75-84.

Gençtürk, T.H., Kaya, İ., Gülağız, F.K. (2023). A Comparative Study on Subdural Brain Hemorrhage Segmentation. *Computational Intelligence, Data Analytics and Applications: Selected papers from the International Conference on Computing, Intelligence and Data Analytics*, Kocaeli, Türkiye, 16-17 Eylül 2022

Kaya, İ., **Gençtürk, T.H.,** & Gülağız, F.K. (2023). A Revolutionary Acute Subdural Hematoma Detection Based on Two-Tiered Artificial Intelligence Model. *Ulusal Travma ve Acil Cerrahi Dergisi*, 29(8). DOI: 10.14744/tjtes.2023.76756



ÖZGEÇMİŞ

İlk, orta ve lise öğrenimini Kocaeli’nde tamamladı. 2017 yılında girdiği Kocaeli Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü’nden 2021 yılında Bilgisayar Mühendisi olarak mezun oldu. 2022 yılından beri Kocaeli Üniversitesi Mühendislik Fakültesinde Araştırma Görevlisi olarak görev yapmaktadır.

