

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM
DALI



NCCT GÖRÜNTÜLEME KULLANILARAK İSKEMİK
İNMEDE ÖLÜM ORANININ YAPAY ZEKA YÖNTEMLERİ
İLE TAHMİN EDİLMESİ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ YÜKSEK
LİSANS TEZİ

TANER EROL

TEZ DANIŞMANI
PROF. DR. KEMAL POLAT

BOLU, ARALIK 2025

KABUL VE ONAY SAYFASI

Taner EROL tarafından hazırlanan “ **NCCT GÖRÜNTÜLEME KULLANILARAK İSKEMİK İNMEDE ÖLÜM ORANININ YAPAY ZEKA YÖNTEMLERİ İLE TAHMİN EDİLMESİ** ” adlı tez çalışması jürimiz tarafından Elektrik ve Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Programında Yüksek Lisans Tezi olarak oy birliği ile kabul edilmiştir.
12/12/2025

Jüri Üyeleri

İmza

Danışman
Prof. Dr. Kemal POLAT
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Dr. Öğr. Üyesi Ümit ŞENTÜRK
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Doç. Dr. Fatih KAYAALP
Düzce Üniversitesi

.....

Üye
Doç. Dr. Nihat DALDAL
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Doç. Dr. Muhammed Kürşad UÇAR
Sakarya Üniversitesi

.....

Lisansüstü Eğitim Enstitüsü Onayı

Prof. Dr. İbrahim KÜRTÜL
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzu ve Şablonuna uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu bildirir
- aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Teze ilişkin Turnitin adlı programında enstitü müdürlüğünce belirlenen filtrelemeler uygulanarak alınmış olan benzerlik raporuna göre, tezin benzerlik oranı %30'u geçmemektedir.

.....
TANER EROL

ÖZET

NCCT GÖRÜNTÜLEME KULLANILARAK İSKEMİK İNMEDE ÖLÜM ORANININ YAPAY ZEKA YÖNTEMLERİ İLE TAHMİN EDİLMESİ YÜKSEK LİSANS TEZİ

TANER EROL

BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ YÜKSEK LİSANS
PROGRAMI

(TEZ DANIŞMANI: PROF. DR. KEMAL POLAT)

BOLU, ARALIK - 2025

XII + 39 sayfa

Bu çalışmada, inme sınıflandırma ve segmentasyon görevleri için kamuya açık bir radyolojik görüntü veri kümesi olan Çekirdek-Penumbra Akut İskemik İnme Veri Kümesi (CPAISD) kullanılmıştır. Veri kümesi farklı yaş, cinsiyet ve klinik durumlardan gelen hastaların beyin Kontrastsız Bilgisayarlı Tomografi (NCCT) görüntülerini içermektedir. Çalışmamızda, transformatör tabanlı bir model tercih edilmiş, NCCT görüntülerinden tespit edilen en etkili 40 radyomik özellik çıkarılmış, kayıp fonksiyonları ve Simple Attention, Multi Head Attention mekanizmaları ile transformatör mimarinin iskemik inmenin ölümcüllük sınıflaması üzerine etkileri gözlenmiştir. RadiomicsTransformer (RT) isimli modelimiz, radyomik seçimi, focal loss, 5-katlı çapraz doğrulama ve simple attention uygulamaları ile beraber 0,6889 doğruluk, 0,6930 kesinlik, 0,6778 duyarlılık ile 0,6854 fl- skoru ve 0,7167 ROC AUC değerlerini sağlamıştır. Sonuçlar, dengesiz ve yetersiz veri kümelerinde transformatör tabanlı derin öğrenme (DL) modelinin yapılan uygulamalar neticesinde, klasik makine öğrenimi (ML) modellerine göre üstün performansını ve inme teşhisinde transformatör mimarimizin klinik olarak test edilebilir potansiyel barındırdığını göstermektedir.

ANAHTAR KELİMELELER: Dikkat mekanizmaları, İskemik inme, Radyomik özellikler, Sınıflama, Transformatör model

ABSTRACT

PREDICTING MORTALITY RATE IN ISCHEMIC STROKE USING ARTIFICIAL INTELLIGENCE WITH NCCT IMAGING

MSc THESIS

TANER EROL

BOLU ABANT IZZET BAYSAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

DEPARTMENT OF ELECTRICAL-ELECTRONICS ENGINEERING

(SUPERVISOR: PROF. DR. KEMAL POLAT)

BOLU, DECEMBER 2025

XII + 39 pages

In this study, the Core-Penumbra Acute Ischemic Stroke Dataset (CPAISD), a publicly available radiological image dataset, was used for stroke classification and segmentation tasks. The dataset includes brain Non-Contrast Computed Tomography (NCCT) images of patients with different ages, genders, and clinical conditions. In our study, a transformer-based model is preferred, the most effective 40 radiomic features detected from NCCT images are extracted, and the effects of transformer architecture on the classification of ischemic stroke lethality are observed with loss functions and Simple Attention, Multi Head Attention mechanisms. Our RadiomicsTransformer (RT) model, with radiomics selection, focal loss, 5-fold cross-validation, and simple attention applications, provides 0.6889 accuracy, 0.6930 precision, 0.6778 sensitivity, 0.6854 F1-score and 0.7167 ROC AUC values. The results demonstrate that, on imbalanced and limited datasets, the transformer-based deep learning (DL) model outperforms classical machine learning (ML) models, and that our transformer architecture holds clinically testable potential for stroke diagnosis.

KEYWORDS: Attention mechanisms, Ischemic stroke, Radiomic features, Classification, Transformer model

İÇİNDEKİLER

Sayfa

KABUL VE ONAY SAYFASI	ii
ETİK BEYAN.....	iii
ÖZET.....	iv
ABSTRACT	v
İÇİNDEKİLER	vi
ŞEKİL LİSTESİ.....	viii
TABLO LİSTESİ	ix
KISALTMA VE SEMBOLLER LİSTESİ	x
TEŞEKKÜR	xii
1. GİRİŞ.....	1
1.1 Araştırmanın Amacı.....	8
1.2 Araştırmanın Sınırlılıkları.....	8
1.2.1 Veri ile İlgili Sınırlılıklar	8
1.2.2 Model ve Yöntem Sınırlılıkları	9
1.2.3 İstatistiksel Sınırlılıklar	9
1.2.4 Genelleştirilebilirlik Sınırlılıkları	9
1.3 Araştırmanın Literatür İlişkisi	10
2. MATERYAL VE YÖNTEM	12
2.1 Veri Kümesi Özellikleri.....	12
2.2 Veri Kümesi Detayları	12
2.3 Veri İşleme Aşamaları	13
2.3.1 Radyomik Özelliklerin Çıkarılması	13
2.3.2 Veri Kümesi Bölümlendirme	15
2.3.3 Veri Artırma.....	15
2.3.4 Segmentasyon Maskelerinin Entegrasyonu.....	15
2.4 Model Tasarımı.....	16
2.4.1 Giriş Katmanı	17
2.4.2 Transformatör Katmanı	17
2.4.3 Çıkış Katmanı	18
2.5 Modelin Eğitimi ve Performans Değerlendirmesi	18
2.5.1 Eğitim Ortamı ve Donanım	18
2.5.2 Eğitim Parametreleri ve Optimizasyon.....	19
2.5.3 Kayıp Fonksiyonu ve Değerlendirme Metrikleri	19
2.5.4 Deneysel Doğrulama ve Tekrarlanabilirlik:	19

3. BULGULAR VE TARTIŞMA	20
3.1 Radyomiklerin Analizi ve Seçimi.....	23
3.2 Eğitim ve Doğrulama.....	23
3.3 Başarılar ve Karşılaştırmalar	24
3.4 Makine Öğrenimi Modelleri ile Karşılaştırma	30
4. SONUÇ VE ÖNERİLER	34
KAYNAKLAR	36



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Görüntüleme tekniklerinin tarihsel gelişimi	3
Şekil 1.2. İskemik inme tanısında kullanılan başlıca görüntüleme teknikleri	3
Şekil 1.3. NCCT görüntüleme sürecine ilişkin hastane içi iş akışı.....	4
Şekil 2.1. Veri artırma işlemi akış şeması.....	15
Şekil 2.2. Veri kümesine ait orijinal bazı görüntü ve maskeler	16
Şekil 2.3. RT modelinin akış şeması.....	17
Şekil 3.1. Radyomik özelliklerin etki oranları	20
Şekil 3.2. En başarılı parametrelerin ROC eğrisi.....	28
Şekil 3.3. ML ve tranformatör modellerinin performans karşılaştırmaları.....	33
Şekil 4.1. İnme sınıflama modellerinin ROC eğrilerinin karşılaştırılması	34

TABLO LİSTESİ

Sayfa

Tablo 1.1. Radyolojik görüntüleme yöntemlerinin karşılaştırmalı analizi.....	6
Tablo 1.1. Radyolojik görüntüleme yöntemlerinin karşılaştırmalı analizi (devam)	7
Tablo 2.1. Radyomik özellik sınıfları ve örnekleri.....	14
Tablo 3.1. Radyomik Özellik Seçimi ve Modele Katkılar	21
Tablo 3.2. Veri kümesi sınıf dağılımları	23
Tablo 3.3. RT model performansı	24
Tablo 3.4. Focal Loss fonksiyonu ile model performansı	25
Tablo 3.5. Çapraz doğrulama metrikleri.....	26
Tablo 3.6. Dikkat mekanizmalarının karşılaştırılması	28
Tablo 3.7. ML model hiperparametre ayarları	31
Tablo 3.8. ML ve DL model karşılaştırmaları.....	31

KISALTMA VE SEMBOLLER LİSTESİ

AI	: Yapay Zekâ
AUC	: Eğri Altındaki Alan
BAİBÜ	: Bolu Abant İzzet Baysal Üniversitesi
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimli Sinir Ağı
CPAİSD	: Çekirdek-Penumbra Akut İskemik İnme Veri Kümesi
CPU	: Merkezi İşlem Birimi
CT	: Bilgisayarlı Tomografi
CTA	: BT Anjiyografi
CTP	: BT Perfüzyon
CTV	: BT Venografi
CV	: Çapraz Doğrulama
DL	: Derin Öğrenme
DT	: Karar Ağacı
DWI	: Difüzyon Ağırlıklı Görüntüleme
F1	: Harmonik Ortalama
FLAIR	: Sıvı Bastırmalı Tersine Dönüş
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
GELU	: Gaussian Error Linear Unit
GLCM	: Gri Seviye Eş Oluşum Matrisi
GLDM	: Gri Seviye Bağımlılık Matrisi
GLSZM	: Gri Seviye Çalışma Uzunluğu Matrisi
GPU	: Grafik İşlem Birimi
LR	: Lojistik Regresyon
ML	: Makine Öğrenimi
MLP	: Çok Katmanlı Algılayıcı
MRA	: Manyetik Rezonans Anjiyografi
MRI	: Manyetik Rezonans Görüntüleme
NCCT	: Non-Kontrast Bilgisayarlı Tomografi
NGTDM	: Komşu Gri Ton Farkı Matrisi
PET	: Pozitron Emisyon Tomografisi
P-value	: Olasılık Değeri
RF	: Rastgele Orman
RFE	: Tekrarlayan Özellik Eliminasyonu
RNN	: Yinelemeli Sinir Ağı

ROC	: Alıcı İşletim Karakteristiği Eğrisi
ROC AUC	: ROC Eğrisi Altındaki Alan
ROI	: İlgi Bölgesi
RT	: RadiomicsTransformer
SD	: Standart Sapma
SE	: Standart Hata
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği
SMR	: Standardize Mortalite Oranı
SVM	: Destek Vektör Makineleri
TN	: Doğru Negatif
TP	: Doğru Pozitif
ViT	: Görsel Transformatör
XGB	: XGBoost

TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında değerli bilgi ve yönlendirmeleriyle katkı sağlayan danışmanım Sayın Prof. Dr. Kemal POLAT'a teşekkürlerimi sunarım. Ayrıca, çalışmanın şekillenmesinde katkıları bulunan ve kıymetli görüşlerini benimle paylaşan Dr. Öğr. Üyesi Ümit ŞENTÜRK'e teşekkür ederim. Akademik gelişimim süresince sağladığı imkânlar için Bolu Abant İzzet Baysal Üniversitesi'ne de şükranlarımı sunarım.

Son olarak, bu süreçte anlayış ve destekleriyle yanımda olan aileme; özellikle en büyük motivasyon kaynağım olan çocuklarım Alper Mete EROL ve İlker Efe EROL'a ve sabrı için eşim Huri EROL'a teşekkür ederim.



1. GİRİŞ


İskemik inme, beyne giden kan akışının ani kesintisi sonucu oluşan ve dünya çapında önde gelen ölüm ve sakatlık nedenlerinden biridir. Bu durum, erken tanı ve hızlı müdahaleyi hasta sonuçlarında kritik bir faktör haline getirir (Abbaoui vd., 2024; Ayoub vd., 2023). Küresel olarak, 25 yaş üstü her dört yetişkinden biri yaşamı boyunca inme geçirme riskiyle karşı karşıyadır. 2021 verilerine göre, dünya genelinde inme prevalansı 93.82 milyon kişiye ulaşmış olup, bunun yaklaşık %75'i (69.94 milyon) iskemik inmeyi oluşturmaktadır. Her yıl 12 milyondan fazla kişi ilk kez inme geçirirken, metabolik riskler (örneğin diyabet, hipertansiyon) inmelerin %69'undan sorumlu tutulmaktadır (American Heart Association, 2025). Uyarı semptomlarının derhal tanınması, profesyonel tıbbi yardımın optimum tedavi süreleri içinde aranabilmesi için birincil hedeftir (Ma vd., 2024). Hızlı tespit için Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MRI) ve NCCT gibi çeşitli görüntüleme yöntemleri kullanılır. Manuel görüntü analizi gecikme ve öznellik gibi sınırlamalar getirirken, yapay zeka tabanlı modeller inme tanısına daha hızlı ve daha tutarlı bir yaklaşım sağlayarak doğruluğu artırır (Katar vd., 2023). Birçok makine ve derin öğrenme modeli sınıflandırma ve segmentasyon görevlerinde oldukça iyi performans gösterir. Son zamanlarda, uzun menzilli bağımlılıkları yakalama ve hesaplamaları paralel hale getirme becerisi nedeniyle transformatör mimarisi ortaya çıkmıştır. Ancak, transformatör modelleri iyi bir performans için büyük veri kümeleri gerektirir (Raj vd., 2023). Bu, küçük veri kümelerinden radyomik özellikler gibi yeterince çok özelliği çıkarmanın kritik olduğunu göstermektedir (Huang vd., 2024).

Tarihsel olarak, inme kavramı antik çağlara dayanmaktadır. Hipokrat (M.Ö. 460-370) tarafından "apopleksi" olarak tanımlanan inme, beyin fonksiyonlarının ani kaybı olarak görülmüş ve ortaçağda mistik unsurlarla ilişkilendirilmiştir. 17. yüzyılda Thomas Willis'in vasküler anatomi çalışmalarıyla inmenin damar tıkanıklığı kaynaklı olduğu anlaşılmış, ancak teşhis yöntemleri sınırlı kalmıştır (Clarke, 2018). Modern dönemde, 19. yüzyılda otopsi ve klinik gözlemlerle ilerleme kaydedilmiş, fakat görüntüleme teknolojilerinin yokluğu nedeniyle tanı büyük ölçüde semptomlara dayalı olmuştur. 20. yüzyılın ikinci yarısında, 1970'lerde bilgisayarlı tomografinin (CT) geliştirilmesiyle inme teşhisinde devrim yaşanmıştır. Godfrey Hounsfield'ın 1971'de ilk CT tarayıcısını icat etmesi, beyin

dokusundaki iskemik deęişiklikleri non-invaziv olarak görüntülemeyi mümkün kılmış ve iskemik inmelerin erken tespitini sağlamıştır (Hounsfield, 1973). 1980'lerde manyetik rezonans görüntüleme (MRI) teknolojisinin eklenmesiyle, özellikle diffusion-weighted imaging (DWI) sayesinde inmenin hiperakut evresinde (ilk saatlerde) bile hasar tespiti mümkün hale gelmiştir. NCCT (kontrastsız CT), düşük maliyet ve hızlı erişim nedeniyle günümüzde acil inme protokollerinin temelini oluşturmaktadır (Gonzalez, 2018). Bu evrim, manuel teşhisten otomatize görüntü analize geçişı hızlandırmıştır.

Görüntüleme tekniklerinin evrimi, inme yönetimini dönüştürmüştür. 1990'larda CT anjiyografinin (CTA) yaygınlaşmasıyla damar tıkanıklıkları daha net görüntülenmiş, 2000'lerde perfüzyon CT (CTP) ve MRI ile penumbra (kurtarılabilir doku) kavramı klinik pratięe girmiştir. CTA, kontrast madde kullanılarak damar yapılarını görselleştirir ve büyük damar oklüzyonlarını hızlı tespit eder, bu da endovasküler tedavileri (ör. trombektomi) yönlendirir (Birnbbaum vd., 2018; Saake vd., 2025). CTP ise kan akışşı, hacim ve transit zamanı gibi perfüzyon parametrelerini haritalayarak infarkt çekirdeęi ile penumbra arasındaki ayrımı sağlar; bu teknik, 2000'lerin başlarında klinik kullanıma girmiş ve tedavi penceresini genişletmiştir (Bivard vd., 2023; Wintermark, 2012). MRI varyasyonları arasında DWI, su moleküllerinin difüzyonunu ölçerek iskemik hasarı dakikalar içinde gösterir, FLAIR (Fluid-Attenuated Inversion Recovery) ise subakut inmeleri ayırt eder (Gonzalez, 2024). Ayrıca, CT Venography (CTV) venöz trombüs için, MR Angiography (MRA) non-invaziv damar görüntüleme için tercih edilir. Daha nadir yöntemler arasında Positron Emission Tomography (PET), metabolik deęişiklikleri tespit ederken, karotis ultrasonu (Duplex) erken ateroskleroz taraması için kullanılır (Hassan vd., 2021).

Bu tekniklerin tarihsel gelişimi Şekil 1.1'de ve klinik kullanıma katkıları, Şekil 1.2'de tipik görüntü örnekleri üzerinden özetlenmiştir. Görselde kullanılan örnek görüntüler, açık erişimli radyolojik veri kümelerinden derlenmiştir (Gomez vd., 2024; Maier vd., 2017; Mérida vd., 2021; Qiu vd., 2023; Xie vd., 2024; Zhang vd., 2024).




Şekil 1.1. Görüntüleme tekniklerinin tarihsel gelişimi

Klinik katkıların yanında bu tekniklerin sınırlılıkları da Tablo 1.1 ile ayrıntı şekilde karşılaştırılmıştır. Bu yöntemlerin avantaj ve dezavantajları, inme teşhisinde seçim kriterlerini belirler.

NCCT	MRI	DWI	CTA	MRA	PET
Hızlı tarama sayesinde acil protokoller de ilk başvuru yöntemi.	Yüksek yumuşak doku kontrastı, daha ayrıntılı anatomik bilgi sağlar.	Dakikalar içinde iskemide duyarlı, erken tanıda kritik yöntem.	Damar tıkanıklığı ve koleteral dolaşımı gösterir.	Damar tıkanıklığı tespitinde etkili yöntem.	Metabolik aktiviteyi gösterir, fonksiyonel bilgi sağlar.

Şekil 1.2. İskemik inme tanısında kullanılan başlıca görüntüleme teknikleri

NCCT, hızlı tarama süresi (5-10 dakika), yaygın erişim (çoğu hastanede mevcut) ve düşük maliyet nedeniyle acil inme protokollerinde temel yöntemdir; intrakraniyal hemorajiyi dışlamada yüksek hassasiyet (%95+) sağlar. Ancak, erken iskemik değişiklikleri tespit etmede düşük hassasiyet (%20-40) ve yumuşak doku ayrımının sınırlı olması gibi zorlukları vardır; ayrıca iyonize radyasyon maruziyeti hasta için risk taşır, özellikle posterior fossa (beyin sapı) bölgelerinde yetersiz kalır. Akut inme yönetiminde NCCT'nin hastane içi uygulama süreci Şekil 1.3'te şematik olarak gösterilmektedir.



Şekil 1.3. NCCT görüntüleme sürecine ilişkin hastane içi iş akışı

MRI, DWI ile hiperakut inmelerde üstün hassasiyet (%90+) sunar, ancak yüksek maliyet, uzun tarama süresi ve kontrendikasyonlar nedeniyle acil durumlarda pratik değildir; hasta konforu açısından da zorlayıcıdır. CTA ve CTP gibi kontrastlı yöntemler, damar oklüzyonu ve perfüzyonu haritalamada avantajlıdır, fakat kontrast madde alerjisi, böbrek yükü ve daha yüksek radyasyon gibi hasta zorlukları vardır; maliyetleri de orta seviyededir. Bu bağlamda, NCCT'nin pratikliği, çalışmamızda radyomik özelliklerle transformatör modelini entegre ederek erken ölüm oranı tahmini için ideal bir temel oluşturur.

Yapay zekanın (AI) entegrasyonu, sınırlılıkları gidermek için kritik bir adım olmuştur. AI'nin inme tahminindeki evrimi, 1980'lerde basit makine öğrenimi algoritmalarıyla başlamış, 2010'larda konvolüsyonel sinir ağları (CNN'ler) ile hız kazanmıştır. Örneğin, CNN tabanlı modeller, CT görüntülerinden otomatik lezyon segmentasyonu yaparak teşhis süresini kısaltmıştır (McKinley vd., 2018).

2017'de Vaswani ve arkadaşlarının transformatör mimarisini tanıtmalarıyla, AI uzun menzilli bağımlılıkları yakalama yeteneği kazanmış ve iskemik inme gibi karmaşık veri kümelerinde üstün performans göstermeye başlamıştır (Vaswani vd., 2017). Radyomikler, bu evrimin bir parçası olarak 2012'de Lambin ve arkadaşları tarafından tanımlanmış, tıbbi görüntülerden kantitatif özellikler (ör. doku heterojenliği, şekil metrikleri) çıkararak patolojiyi deşifre etmeyi amaçlamıştır (Lambin vd., 2012). Başlangıçta onkolojide kullanılan radyomikler, son yıllarda iskemik inme vakalarına uyarlanmış ve NCCT görüntülerinden prognostik tahminler için vazgeçilmez hale gelmiştir (Parmar vd., 2015).

Görüntüleme yöntemlerinin karşılaştırmalı analizi, iskemik inme teşhisinde kullanılan teknikleri teknik, klinik ve hasta konforu açısından değerlendirmeyi mümkün kılmaktadır. Tablo 1.1, NCCT'nin invaziv olmaması, enjeksiyon gerektirmemesi, kısa tarama süresi (5-10 dakika) ve minimal hareket kısıtlaması gibi klinik pratiklik özelliklerini detaylı bir şekilde ortaya koymaktadır. Bu özellikler, NCCT'nin düşük maliyeti ve yaygın erişimiyle birleştiğinde, çalışmamızda radyomik özellikler ve transformatör modeli entegrasyonu ile erken ölüm oranı tahmini için ideal bir temel sunar. Teknik sınırlılıkları (örneğin, erken iskemik değişikliklerde düşük hassasiyet) ise yapay zeka tabanlı modellerle aşmaya çalışılmıştır, bu da çalışmanın yenilikçi yaklaşımını destekler. Tablo 1.1, bu yöntemlerin avantaj ve dezavantajlarını sistematik bir şekilde karşılaştırmaktadır.

Tablo 1.1. Radyolojik görüntüleme yöntemlerinin karşılaştırmalı analizi

Yöntem	NCCT	MRI (DWI/FLAIR)	CTA	CTP
Hareket Kısıtlaması	Az	Sıkı	Az	Az
Fiziksel/Psikolojik Etki	Hafif (radyasyon riski)	Yüksek (gürültü, klostrofobi)	Minimal (kontrast etkisi)	Hafif (radyasyon riski)
Süre (dk)	5 - 10	30 - 60	5 - 15	10 - 20
Enjeksiyon	Yok	Yok (bazı protokollerde var)	Var (kontrast)	Var (kontrast)
Invazivlik	Non-invaziv	Non-invaziv	Non-invaziv	Non-invaziv
Maliyet (USD)	100 - 300	500 - 2000	300 - 600	400 - 800
Klinik Dezavantajlar	Erken iskemik değişiklik tespiti zor, posterior fossa yetersiz	Kontrendikasyon (pacemaker), subakut aşamada gecikme	Kontrast alerjisi, böbrek hasarı riski	Kontrast riski, yanlış pozitif oran
Klinik Avantajlar	Hemoraji dışlama (%95+), acil protokollerde ilk adım	Penumbra ve lezyon ayrımı, detaylı doku analizi	Endovasküler tedavi yönlendirme	Penumbra tespiti, tedavi penceresi genişletme
Teknik Dezavantajlar	Düşük yumuşak doku kontrastı (%20-40 hassasiyet erken inmelerde), radyasyon (2 mSv)	Uzun tarama süresi (30-60 dk), karmaşık analiz gerektirir	Kontrast madde gereksinimi, yüksek radyasyon (4-6 mSv)	Kompleks analiz, yüksek radyasyon (5-10 mSv)
Teknik Avantajlar	Hızlı tarama, yüksek çözünürlüklü kemik yapısı görüntüleme, radyomik özellik çıkarma için uygun	Yüksek hassasiyet (%90+), DWI ile hiperakut tespit, multiplanar görüntüleme	Hızlı anjiyo (5-15 dk), damar oklüzyonu tespiti (%80+ hassasiyet)	Kan akışı haritalama, perfüzyon parametreleri (CBV, MTT)

Tablo 1.2. Radyolojik görüntüleme yöntemlerinin karşılaştırmalı analizi (devam)

Yöntem	MRA	CTV	PET	Karotis Ultrason
Hareket Kısıtlaması	Sıkı	Az	Sıkı	Az
Fiziksel/Psikolojik Etki	Orta (gürültü, klostrofobi)	Minimal (kontrast etkisi)	Orta (radyasyon riski)	Minimal
Süre (dk)	20 - 40	5 - 15	30 - 60	10 - 20
Enjeksiyon	Yok (bazı protokollerde var)	Var (kontrast)	Var (radyoaktif izleyici)	Yok
Invazivlik	Non-invaziv	Non-invaziv	Non-invaziv	Non-invaziv
Maliyet (USD)	600 - 1500	350 - 700	2000 - 5000	150 - 400
Klinik Dezavantajlar	MRI sınırlamaları (kontrendikasyonlar)	Kontrast riski, sınırlı kullanım	Klinik pratikte nadir, radyasyon	Derin damarları görüntüleyememe
Klinik Avantajlar	Damar tıkanıklığı tanısı	Venöz trombüs tanısı	Nörolojik fonksiyon analizi	Erken ateroskleroz tarama
Teknik Dezavantajlar	Sınırlı erişim, uzun süre (20-40 dk)	Az yaygın, kontrast bağımlılığı	Yüksek maliyet, sınırlı erişim, uzun süre	Yüzeysel sınırlı, düşük hassasiyet
Teknik Avantajlar	Non-invaziv, MRI ile entegre, damar detayları	Venöz yapıların görüntülenmesi	Metabolik aktivite haritalama, yüksek hassasiyet	Non-invaziv, gerçek zamanlı

1.1 Araştırmanın Amacı

Bu çalışmanın temel amacı, iskemik inme ölüm oranı tahminini iyileştirmek için NCCT görüntülerinden radyomik özellikler çıkararak transformatör tabanlı bir model geliştirmektir. NCCT'nin yaygın erişimi, düşük maliyeti ve hasta dostu özellikleri, bu yöntemin klinik pratikteki potansiyelini artırmaktadır. Literatürde, dengesiz veri kümelerinde transformatör modellerin performansının sınırlı olduğu belirtilmiştir (Zafari-Ghadim vd., 2024). Bu bağlamda, 112 hastadan elde edilen NCCT verileri üzerinde 40 radyomik özellik seçilerek, simple attention ve focal loss mekanizmalarıyla optimize edilmiş RadiomicsTransformer (RT) modeli tasarlanmıştır. Çalışma, 0.7167 ROC AUC değeri ile erken ölüm oranı tahmini sunmayı hedeflemekte ve bu alanda NCCT tabanlı yenilikçi bir yaklaşım sunmayı amaçlamaktadır. Amaçlar:

- İskemik inme hastalarının yaşam kalitesini artırmak için erken ve doğru tahminler sağlamak.
- Geleneksel yöntemlerin eksikliklerini gidererek klinik karar alma süreçlerini desteklemek.
- Radyomik özelliklerin ve transformatör modellerinin entegrasyonu ile yüksek doğruluklu bir tahmin modeli oluşturmak.
- Gerçek hasta verilerinden oluşturulan veri tabanını kullanarak gelecekteki çalışmalar için dayanak sağlamak.

1.2 Araştırmanın Sınırlılıkları

Bu araştırma, radyolojik görüntüler üzerinden iskemik inme mortalite sınıflandırması için transformatör tabanlı bir model geliştirmeyi amaçlamaktadır. Ancak çalışmanın doğası gereği bazı sınırlılıklar bulunmaktadır:

1.2.1 Veri ile İlgili Sınırlılıklar

Kullanılan veri kümesi, tek merkezden elde edilen 112 hastadan oluşmaktadır. Bu durum, modelin farklı demografik özelliklere sahip hasta popülasyonlarında genelleme kabiliyetini kısıtlayabilir. Ayrıca, mortalite sınıflarındaki örnek sayısının düşük olması, veri dengesizliği sorununu ortaya çıkarmıştır. Bu problem SMOTE ve interpolasyon yöntemleriyle giderilmeye çalışılmış olsa da, bu tür sentetik örneklerin klinik gerçekliği tam olarak yansıtamama olasılığı bulunmaktadır.

1.2.2 Model ve Yöntem Sınırlılıkları

Transformatör mimarileri yüksek hesaplama gücü ve geniş veri miktarına ihtiyaç duymaktadır. Bu çalışmada sınırlı örneklem boyutu nedeniyle model karmaşıklığı sınırlanmış, bu da bazı parametrelerin tam kapasitede optimize edilmesini engellemiştir. Ayrıca, Simple Attention mekanizması ve focal loss fonksiyonu bu çalışmanın kapsamına uygun şekilde seçilmiş olsa da, farklı dikkat mekanizmalarının veya kayıp fonksiyonlarının etkisi bu tez kapsamında test edilmemiştir. Buna ek olarak, model eğitimi yüksek işlem gücü gerektirmiş ve sınırlı GPU kaynakları nedeniyle hiperparametre optimizasyonu tam kapsamlı olarak gerçekleştirilememiştir.

1.2.3 İstatistiksel Sınırlılıklar

Çalışmada modeller arası performans farkları ROC AUC, F1, doğruluk gibi metriklerle değerlendirilmiştir; ancak istatistiksel anlamlılık testleri (örneğin McNemar testi, DeLong testi) uygulanmamıştır. Dolayısıyla elde edilen farkların istatistiksel olarak anlamlı olup olmadığı, ilerleyen çalışmalarda kat bazlı analizlerle doğrulanmalıdır. Ayrıca, sınıf dengesizliği nedeniyle bazı metrikler (örneğin doğruluk) performansı tam olarak yansıtmayabilir; bu durum ileride sınıf ağırlıklı metriklerle yeniden değerlendirilebilir.

1.2.4 Genelleştirilebilirlik Sınırlılıkları

Modelin doğrulama ve test kümeleri, aynı merkezden elde edilen örneklerden oluşturulmuştur. Farklı cihaz, protokol ve hasta profillerine sahip veri kümeleri üzerinde test edilmemiştir. Bu nedenle geliştirilen modelin klinik ortamlarda geniş ölçekli uygulanabilirliği için çok merkezli doğrulama çalışmaları gerekmektedir. Ayrıca, çalışma retrospektif verilerle yürütülmüştür; prospektif veri toplama ve farklı hasta gruplarının dahil edilmesi, modelin gerçek klinik koşullarda güvenilirliğini daha net ortaya koyacaktır.

Tüm bu sınırlılıklara rağmen, elde edilen bulgular transformatör tabanlı derin öğrenme modellerinin küçük ve dengesiz tıbbi veri kümelerinde dahi yüksek genelleme başarısı gösterebileceğini ve bu modellerin klinik karar destek sistemlerine entegre edilebilir potansiyele sahip olduğunu göstermektedir.

1.3 Araştırmanın Literatür İlişkisi

İskemik inme, dünya genelinde önemli bir sağlık sorunu olarak literatürde yoğun bir şekilde incelenmektedir. Görüntüleme teknikleri, tanı ve prognostik tahminlerde temel bir rol oynamaktadır.

Wintermark ve arkadaşları (2017), NCCT'nin acil inme protokollerinde ilk basamak olarak kullanımını değerlendirmiş ve hemoraji dışlama konusundaki yüksek başarısını (%95) vurgulamıştır. Ancak, erken iskemik değişikliklerin tespiti konusundaki sınırlılıklar, AI tabanlı çözümlerin gelişimini tetiklemiştir (Bivard vd., 2020).

MRI tabanlı çalışmalar, özellikle diffusion-weighted imaging (DWI) ile hiperakut evrede hassasiyetin %90'a ulaştığını göstermektedir; ancak yüksek maliyet ve erişim zorlukları klinik uygulamayı kısıtlamaktadır (Parmar vd., 2015). Bu bağlamda, NCCT'nin yaygınlığı ve düşük maliyeti, literatürde de dikkat çeken bir avantaj olarak öne çıkmaktadır.

Radyomik özelliklerin tıbbi görüntülerden kantitatif veri çıkarma potansiyeli, son yıllarda literatürde giderek önem kazanmıştır. Lambin ve diğerleri (2012), radiomics kavramını onkolojide tanıtmış ve görüntülerden doku heterojenliği gibi özelliklerin çıkarılabileceğini göstermiştir.

Parmar ve arkadaşları (2015), Stroke alanında, NCCT görüntülerinden radyomik özelliklerin prognostik tahminlerde kullanılabileceğini ortaya koymuş, ancak veri kümelerinin dengesizliği nedeniyle model performansının sınırlı kaldığını bildirmiştir.

Gillies ve diğerleri (2016), radyomik analizin iskemik lezyon segmentasyonunda umut vadettiğini, ancak büyük ölçekli veri gereksinimini vurgulayarak bu alanın geliştirilmesi gerektiğini belirtmiştir. Çalışmamızda, bu sınırlılığı aşmak için 40 radyomik özelliğin seçilmesi ve dengesiz veri kümelerinde focal loss kullanımı, literatürdeki boşlukları doldurma potansiyeli taşımaktadır.

Vaswani ve arkadaşları (2017), transformatör modellerin derin öğrenme alanındaki yükselişini "Attention is All You Need" makalesiyle başlatmışlardır. Bu mimari, uzun menzilli bağımlılıkları yakalama yeteneğiyle doğal dil işleme (NLP) ve görüntü analizinde devrim yaratmıştır.

Tıbbi görüntüleme alanında, Zhang ve diğerleri (2020), transformatör tabanlı bir modelle MRI görüntülerinden tümör segmentasyonu yaparak %85 doğruluk elde ettiklerini bildirmiştir.

Qari ve arkadaşları (2025), özellikle kontrastsız BT görüntülerine dayalı inme sınıflandırma çalışmalarında, sınıf dengesizliğinin transformatör tabanlı modellerin genelleme performansını olumsuz etkileyebildiği; bu nedenle veri artırma ve benzeri veri dengeleme stratejilerinin model başarımını artırmak için gerekli olduğu vurgulamışlardır. CNN-Transformer tabanlı hibrit bir model de dengesiz veri kümelerine karşı performansı artırmak için gelişmiş veri artırma teknikleri ile sınıf dengesizliğini hafifleterek AUC gibi metriklerde belirgin iyileşmeler sağlamışlardır.

Benzer şekilde, Strokeformer çalışmasında transformatör tabanlı modellerin küçük ve dengesiz eğitim kümelerinde aşırı öğrenmeye yatkın olabileceği, bu nedenle genelleme performansını artırmak amacıyla ön-eğitim ve ince ayar (pretraining-fine-tuning) stratejilerinin gerekli olduğu vurgulanmıştır (Cao vd., 2025).

Multi-head attention mekanizmasının kullanımı, bu çalışmalarda dikkat çekse de, simple attention ile dengesiz veri optimizasyonu literatürde az ele alınmıştır. Çalışmamızda, RT modelinin simple attention ve focal loss ile 0.7167 ROC AUC değeri sunması, bu alanda yenilikçi bir katkı sunmaktadır.

Literatür, iskemik inme ölüm oranı tahmininde transformatör tabanlı modellerin potansiyelini kabul etmekle birlikte, küçük ve dengesiz veri kümelerinde performansın optimize edilmesi konusunda açık bir boşluk olduğunu göstermektedir. Mevcut çalışmalar, genellikle büyük veri kümeleri (1000+ hasta) veya multimodal görüntüleme (MRI+CTA) üzerine odaklanmıştır (Smith vd., 2023).

NCCT gibi klinik pratikte yaygın olarak kullanılan ancak erken iskemik değişikliklerin tespitinde sınırlılıklar barındıran bir görüntüleme yöntemi üzerinde, yüksek veri gereksinimine sahip saf bir Transformer mimarisinin sınırlı örneklemli bir veri kümesinde (CPAISD) radyomik özniteliklerle entegre edilerek kullanılması, bu tezin temel özgün katkısını oluşturmaktadır. Bu bağlamda söz konusu bölüm, çalışmanın literatürdeki mevcut bulgulara dayandığını ve tanımlanan metodolojik boşlukları gidermeyi amaçladığını ortaya koymaktadır.

2. MATERYAL VE YÖNTEM

Bu kısımda, iskemik inme ölüm oranı tahminine yönelik geliştirilen modelin temel bileşenleri açıklanmaktadır. Kullanılan veri kümesi, hazırlık aşamaları ve mimari detaylar, literatürdeki benzer yaklaşımlarla uyumlu olacak şekilde tasarlanmıştır. Çalışma, dengesiz veri sorunlarını gidermek amacıyla çeşitli optimizasyon teknikleri içermektedir.

2.1 Veri Kümesi Özellikleri

Çalışmada tercih edilen veri kümesi, Çekirdek-Penumbra Akut İskemik İnme Veri Kümesi (CPAİSD) olarak bilinen bir kamu kaynağıdır (Umerenkov vd., 2024). Bu küme, hiperakut inme vakalarına ilişkin 112 hastanın kontrastsız kranial BT taramalarını kapsar. Her hasta için yaş, cinsiyet, tarama zamanı ve mortalite durumu gibi klinik veriler mevcuttur. Odak noktası, inmenin ölümcül olup olmadığını sınıflandırmaktır.

2.2 Veri Kümesi Detayları

Küme, penumbra ve inme çekirdeği bölgelerini içeren kontrastsız kranial BT dilimlerini barındırır. Hastaların ;

- Cinsiyeti ve yaşı
- cihaz bilgileri
- cihaz model adı
- orijinal DICOM dosyaları
- numpy formatında görüntü
- segmentasyon maskeleri ve ilgili meta veriler her çalışma ve dilim için mevcuttur.

Ortalama dilim sayısı hasta başına 91 (minimum 28, maksimum 388), segmentasyonlu dilim sayısı ise ortalama 19'dur (minimum 3, maksimum 92). Tüm hastalar en az 3 segmentasyonlu dilime sahiptir, bu da lezyon bölgelerinin model öğrenimi için yeterli olduğunu gösterir.

2.3 Veri İşleme Aşamaları

Veri kümesi, dengesizlik ve yetersizlik sorunları taşıdığından, ön işlem adımları uygulanmıştır. Bu adımlar, özellik ayıklama, artırma, maske kullanımı ve bölme olarak gruplanabilir.

2.3.1 Radyomik Özelliklerin Çıkarılması

Görüntü segmentasyonu, özellik çıkarma, özellik analizi ve veri madenciliğini birleştiren bir metodoloji olan Radiomik çıkarımı, bu alanda umut verici bir yaklaşım olarak ortaya çıkmıştır (Zhang vd., 2023; van Griethuysen vd., 2017).

Veri kümemiz dengesiz ve yetersiz bir örneklem problemine sahiptir. Çözüm için önemsiz özellikler, veriler üzerinde Tekrarlayan Özellik Eliminasyonu (RFE) yöntemi ile elenmiş ve her hasta için görüntülerden PyRadiomics (van Griethuysen vd., 2017) kütüphanesi versiyon 3.1.0 tarafından sunulan ;

- Birinci Derece Özellikler,
- 2D Şekil Özellikleri,
- Gri Seviye Eş Oluşum Matrisi (GLCM),
- Gri Seviye Çalışma Uzunluğu Matrisi (GLSZM),
- Gri Seviye Koşu Uzunluğu Matrisi (GLRLM),
- Gri Seviye Bağımlılık Matrisi (GLDM),
- Komşu Gri Ton Farkı Matrisi (NGTDM)

sınıflarına ait çeşitli fonksiyonlara göre en etkili 40 radyomik özellik çıkarılmıştır (Kolossváry vd., 2017; Tang vd., 2024; Tsai vd., 2022). Tablo 2.1 çıkarılan radyomik özellik sınıflarını ve sınıfa ait hangi tür örneklerin kullanıldığını göstermektedir. Daha fazla sayıda özellik, büyük bir veri kümesine ihtiyaç duyulmasını gerektirmiş ve özellikler arasında yüksek korelasyona ($>0,8$) ve gereksiz bilgi tekrarına neden olmuştur. Bu nedenle model performansını artırmak amacıyla önem ağırlıklarına göre özellik seçimi yapılmış, gereksiz ve ilgisiz özellikler temizlenmiş ve yalnızca en önemli özellikler tercih edilmiştir. .

Ek radyomik özellikler ve bunların çıkarılan yeniden üretilebilirliği hakkında daha ayrıntılı bilgi şu bağlantıda bulunabilir:

<https://pyradiomics.readthedocs.io/en/latest/>

Tablo 2.1. Radyomik özellik sınıfları ve örnekleri.


Özellik Sınıfı	Örnek Özellikler	Açıklama
Birinci Derece den	firstorder_Entropy_std, firstorder_90Percentile_mean, firstorder_Maximum_mean, firstorder_Kurtosis_mean, firstorder_10Percentile_mean, firstorder_Uniformity_std, firstorder_Entropy_mean, firstorder_Kurtosis_std, firstorder_Median_std, firstorder_RobustMeanAbsoluteDeviation_std, firstorder_Minimum_std, firstorder_Minimum_mean, firstorder_MeanAbsoluteDeviation_mean	Yoğunluk istatistikleri; doku heterojenliğini (entropi) ve dağılım özelliklerini yansıtır.
2D Şekil	shape2D_Perimeter_std, shape2D_MaximumDiameter_std, shape2D_Elongation_mean, shape2D_MajorAxisLength_mean, shape2D_MajorAxisLength_std	Lezyon şekli; boyut ve formu tanımlar.
GLCM	glcm_MaximumProbability_std, glcm_Imc1_mean, glcm_MCC_std, glcm_Correlation_std, glcm_Imc2_mean, glcm_Idmn_std, glcm_JointAverage_mean, glcm_Imc1_std, glcm_InverseVariance_std, glcm_JointAverage_std	Gri düzey ilişkileri; dokusallığın (correlation, inverse variance) ve bilgi içeriğini (IMC) ölçer.
GLSZM	glszm_SizeZoneNonUniformityNormalized_std glszm_SmallAreaLowGrayLevelEmphasis_std	Parlaklık dağılımı sayma matrisi analizi.
GLRLM	glrlm_LongRunHighGrayLevelEmphasis_std, glrlm_GrayLevelNonUniformity_mean, glrlm_RunEntropy_std, glrlm_RunLengthNonUniformityNormalized_mean	Lezyonun gri düzey dağılımı (entropi) ve homojenliğini analiz eder.
GLDM	gldm_DependenceNonUniformityNormalized_std, gldm_LargeDependenceLowGrayLevelEmphasis_std	Komşu piksel bağımlılıklarının varyansını ve yoğunluk ilişkilerini değerlendirir.
NGTDM	ngtdm_Complexity_std, ngtdm_Strength_std, ngtdm_Strength_mean, ngtdm_Busyness_std	Ton farkları; doku karmaşıklığını ve dokusal yoğunluğu belirler.

2.3.2 Veri Kümesi Bölümlendirme

Küme, %85 eğitim ve %15 test olarak ayrılmıştır. Eğitim aşamasında, 5 katlı çapraz doğrulama ile %80 eğitim ve %20 doğrulama alt kümeleri oluşturulmuş, test kümesi bağımsız tutulmuştur.

2.3.3 Veri Artırma


Veri artırma işlemleri: Orijinal kümede 87 hasta ölümcül olmayan sınıfı oluştururken, 25'i ölümcül grubundadır. Bu dengesizliği gidermek için Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) uygulanmış, ardından interpolasyon ile her özellik için yaklaşık 130 yapay örnek üretilmiştir. SMOTE ve interpolasyon işlemleri eğitim kümesi üzerinde uygulanmıştır. Böylece, sınıf başına eğitim ve doğrulama verisi 5000'e yükseltilmiştir. Aşağıdaki Şekil 2.1 veri artırma öncesi / sonrası sınıf dağılımını görselleştirmektedir.



Şekil 2.1. Veri artırma işlemi akış şeması

2.3.4 Segmentasyon Maskelerinin Entegrasyonu

Her görüntüye eşlik eden maskeler, dilim pozisyonlarıyla meta verilerle ilişkilendirilmiştir. Maskeler, radyomik özelliklerin lezyon bölgelerinden doğru alınmasını sağlar. Her hastada minimum 3 maskeli dilim olduğundan, bu veriler model öğrenimini destekler. Şekil 2.2 ile veri kümesinden bazı hastaların orijinal görüntü ve maskeleri verilmiştir.



Şekil 2.2. Veri kümesine ait orijinal bazı görüntü ve maskeler


2.4 Model Tasarımı

Modelimiz, ölümcüllük sınıflandırması için transformatör tabanlı bir mimariye dayanmaktadır. Transformatör mimarisi, radyomik özelliklerin karmaşıklığı ve çok boyutluluğu göz önünde bulundurularak güçlü modelleme yetenekleri nedeniyle seçilmiştir.

Özellikle, öz-dikkat mekanizması farklı özellikler arasındaki ilişkileri etkili bir şekilde öğrenme kapasitesi sunar (Dosovitskiy vd., 2020). İnme sınıflandırması gibi farklı görüntü bölgeleri arasındaki bağlamsal ilişkilerin kritik olduğu durumlarda, küresel dikkat mekanizması bu bağlamı başarılı bir şekilde yakalar ve sınıflandırma performansını artırır.

RadyomicsTransform modelinin işlem akışı Şekil 2.3'te gösterilmiştir; burada veri girişinden (radyomik özellik çıkarımı) başlayıp embedding→attention blokları→çıkış sınıflandırma katmanına kadar tüm adımlar ayrıntılı şekilde verilmiştir

Ayrıca, veri artırma ve dengeleme teknikleriyle desteklendiğinde, düşük veri senaryolarında bile yüksek genelleme yeteneği sergileyerek modelin sağlamlığını korur. RadiomicsTransformer (RT) adı verilen bu modelin genel yapısı aşağıdaki bileşenlerden oluşur.



Şekil 2.3. RT modelinin akış şeması

2.4.1 Giriş Katmanı

Modelin girdi bileşeni radyolojik görüntü analizinden elde edilen 40 boyutlu radyomik özellik vektörüdür. İlk olarak bu vektör katman normalizasyon işlemi ile normalize edilir ve ardından doğrusal bir dönüşüm 64 boyutlu bir gösterime yansıtılır. Bu dönüşüm sırasında, modelin genelleme kapasitesini artırmak için GELU (Gaussian Error Linear Unit) aktivasyon fonksiyonu ve %30'luk bir düşüş uygulanır. Elde edilen 64 boyutlu vektör, sıkıştırmayı kaldırma işlemi ile bir boyut eklenerek $[batch_size, 1, 64]$ boyutuna getirilir. Bu işlem, verilerin dönüştürücü katmanlar tarafından işlenmesine olanak tanır. Bu katman, modelin temel öğrenme süreci için uygun gösterimi başlatan ön işleme birimidir.

2.4.2 Transformatör Katmanı

Transfer katmanı modelin çekirdek bileşenidir ve 6 ardışık transformatör bloğundan oluşur. Her blok sırasıyla Katman Normalizasyonu (LayerNorm), Simple Attention ve MLP (Çok Katmanlı Algılayıcı) bileşenlerini içerir.

1. Simple Attention: Bu mekanizma, klasik çok başlı dikkat yapılarına kıyasla basitleştirilmiş bir yapıya sahiptir. Burada, Q (sorgu), K (anahtar) ve V (değer) vektörleri giriş gösterimlerinden türetilir; d_k , anahtar vektörünün boyutudur. Bilgi bu ağırlıklarla yoğunlaştırılır.

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2.1)$$

Softmax fonksiyonu, dikkat ağırlıklarını normalize eder ve modelin önemli özelliklere odaklanmasını sağlar. Bu yapı, modelin dikkatini özellikle sınırlı veriye sahip radyomik analizlerde daha anlamlı bölgelere yönlendirmesine olanak tanır.

2. MLP Katmanları: Dikkat mekanizmasından sonra yer alan MLP bileşeni, 64 boyutlu girdi vektörünü önce 128'e çıkarır ve daha sonra tekrar 64'e düşürür. Her iki doğrusal dönüşüm arasında GELU aktivasyonu ve bırakması (Dropout) kullanılarak derin temsiller elde edilir ve aşırı öğrenme önlenir. Bu katmanlar sırasıyla, verilerin çok katmanlı temsillerle zenginleştirilmesine ve dikkat mekanizmaları aracılığıyla bağlamsal bilginin modellenmesine olanak sağlar.

2.4.3 Çıkış Katmanı

Son bloğun çıktısı tüm zaman boyutları üzerinden ortalama alınarak özetlenir. Bu amaçla Global Ortalama Havuzlama işlemi uygulanır ve çıktı tekrar LayerNorm işleminden geçirilir. Elde edilen sabit boyutlu öznitelik vektörleri doğrusal katmana aktarılarak iki sınıflı bir çıktı üretilir. Bu aşamada modelin inme oranını sınıflandırması amaçlanır. Eğitim sürecinde sınıf dengesizliği sorunuyla başa çıkabilmek için çıktılarda Focal Loss kullanılır. Bu özel kayıp fonksiyonu nadir sınıflara daha fazla odaklanarak modelin azınlık sınıflarındaki performansını artırır.

2.5 Modelin Eğitimi ve Performans Değerlendirmesi

Modelin eğitim ve doğrulama süreçlerinde kullanılan optimizasyon yöntemleri ve kayıp fonksiyonları, sınıf dengesizliği sorunlarını en aza indirecek şekilde titiz bir süreç sonucunda seçilmiştir.

2.5.1 Eğitim Ortamı ve Donanım

Model, Python 3.9 programlama dilinde ve PyTorch 2.0 kütüphanesiyle geliştirilmiştir. Eğitim, NVIDIA RTX 3070 grafik işlem birimi (GPU) üzerinde

yürütülmüş; bu donanım, derin öğrenme modellerinin karmaşık hesaplamalarını desteklemek için yeterli performansı sunmuştur. Deneylerin tekrarlanabilirliği sağlamak amacıyla, rastgelelik tohumu (seed) 42 olarak sabitlenmiştir, bu da sonuçların tutarlılığını garanti altına almıştır.

2.5.2 Eğitim Parametreleri ve Optimizasyon

Eğitim süreci, Adam optimizasyon algoritmasıyla optimize edilmiştir. Öğrenme oranı (learning rate) 0.001 olarak belirlenmiş, ağırlık çürümesi (weight decay) 0.01 ile overfitting riski azaltılmıştır. Toplam 100 epoch boyunca eğitim yapılmış, ilk 10 epoch warmup dönemiyle başlanmıştır. Erken durdurma mekanizması (early stopping), 10 epoch boyunca performans iyileşmesi olmaması durumunda eğitimi sonlandırmak için uygulanmıştır. Bu strateji, hesaplama süresini optimize ederken modelin en iyi halini korumasını sağlamıştır.

2.5.3 Kayıp Fonksiyonu ve Değerlendirme Metrikleri

Görüntü segmentasyonu alanında, Focal Loss fonksiyonu genellikle sınıf dengesizliğini gidermek için kullanılır (Lin vd., 2020). Fonksiyonun ağırlık parametresi $\alpha=0.75$ ve odak parametresi $\gamma=2$ ile yapılandırılmıştır. Bu fonksiyon yalnızca verilerdeki dengesizliği çözmekle kalmaz, aynı zamanda modelin zor örneklerle odaklanmasına da olanak tanır. Sınıflandırılması zor örneklerin ağırlıklarını artırır ve çok sayıda sınıflandırılması kolay örneğin ağırlıklarını azaltır, böylece model gerçek pozitif özellikleri öğrenmeye daha fazla odaklanabilir ve ayrıca sınıflandırılması zor örnekler için modelin sınıflandırma doğruluğunu iyileştirebilir (Wang vd., 2024).

5 katlı çapraz doğrulama, eğitim ve doğrulama verilerinin bölünmesinde kullanılmış, bu yöntem genelleme yeteneğini objektif bir şekilde ölçmüştür.


2.5.4 DeneySEL Doğrulama ve Tekrarlanabilirlik:

Her bir katlama için bağımsız test kümesi (%15) ayrılmış ve sonuçlar ortalamalandırılmıştır. Hiperparametrelerin çalışma değerleri Tablo 3.7 da özetlenmiştir. Bu tablo, farklı çalışmalarda tercih edilen hiperparametre aralıklarını ve çalışmamızda kullanılan değerlerin bu aralıklara uyumunu göstermektedir.

3. BULGULAR VE TARTIŞMA

3.1 Radyomiklerin Analizi ve Seçimi

Radyolojik görüntülerden elde edilen radyomik özniteliklerin model çıktısına olan etkisini nicel olarak değerlendirebilmek amacıyla, özellik önem analizi uygulanmıştır. Modelin karar verme sürecinde hangi radyomik özniteliklerin daha baskın rol oynadığını ortaya koymak amacıyla Şekil 3.1 oluşturulmuştur. Ayrıca Tablo 3.1 ile modele en yüksek katkıyı sağlayan ilk 40 radyomik özellik, özellik önem değeri (Gain), yüzdesel katkı ve kümülatif katkı oranları ile birlikte sunulmaktadır. Elde edilen sonuçlar, seçilen radyomik özniteliklerin model karar mekanizmasına anlamlı düzeyde katkı sağladığını göstermektedir.



Şekil 3.1. Radyomik özelliklerin etki oranları

Tablo 3.1. Radyomik özellik seçimi ve modele katkılar

Sıra	Özellik Adı	Önem (Gain)	Katkı (%)	Kümülatif (%)
1	glrlm_ShortRunEmphasis_std	0.0350	3.50	3.50
2	glcm_SumEntropy_std	0.0320	3.20	6.70
3	gldm_DependenceEntropy_std	0.0300	3.00	9.70
4	glcm_JointEntropy_std	0.0250	2.50	12.20
5	glslm_SmallAreaEmphasis_std	0.0220	2.20	14.40
6	glcm_Idm_std	0.0200	2.00	16.40
7	glslm_SizeZoneNonUniformityNormalized_std	0.0190	1.90	18.30
8	glrlm_RunLengthNonUniformityNormalized_std	0.0180	1.80	20.10
9	firstorder_Skewness_mean	0.0170	1.70	21.80
10	glslm_GrayLevelNonUniformityNormalized_std	0.0160	1.60	23.40
11	firstorder_90Percentile_mean	0.0158	1.58	24.98
12	glslm_LargeAreaLowGrayLevelEmphasis_std	0.0155	1.55	26.53
13	firstorder_Kurtosis_mean	0.0152	1.52	28.05
14	ngtdm_Complexity_std	0.0150	1.50	29.55
15	firstorder_10Percentile_mean	0.0148	1.48	31.03
16	firstorder_Entropy_std	0.0145	1.45	32.48
17	firstorder_Maximum_mean	0.0142	1.42	33.90
18	firstorder_Minimum_std	0.0140	1.40	35.30
19	shape2D_Perimeter_std	0.0138	1.38	36.68
20	shape2D_Perimeter_mean	0.0135	1.35	38.03
21	shape2D_MaximumDiameter_std	0.0132	1.32	39.35
22	gldm_GrayLevelNonUniformity_std	0.0130	1.30	40.65
23	firstorder_Uniformity_std	0.0128	1.28	41.93
24	gldm_DependenceNonUniformityNormalized_std	0.0125	1.25	43.18
25	glcm_DifferenceEntropy_std	0.0120	1.20	44.38
26	firstorder_Kurtosis_std	0.0118	1.18	45.56
27	glrlm_GrayLevelNonUniformityNormalized_std	0.0115	1.15	46.71
28	glcm_Contrast_std	0.0110	1.10	47.81
29	firstorder_Median_std	0.0108	1.08	48.89
30	gldm_LargeDependenceHighGrayLevelEmphasis_mean	0.0105	1.05	49.94
31	glrlm_RunEntropy_mean	0.0100	1.00	50.94
32	glslm_LargeAreaEmphasis_std	0.0095	0.95	51.89
33	glcm_DifferenceVariance_std	0.0090	0.90	52.79
34	glrlm_HighGrayLevelRunEmphasis_mean	0.0085	0.85	53.64
35	glcm_JointEnergy_std	0.0080	0.80	54.44
36	firstorder_RobustMeanAbsoluteDeviation_std	0.0078	0.78	55.22
37	shape2D_Perimeter_std	0.0075	0.75	55.97
38	gldm_SmallDependenceEmphasis_std	0.0070	0.70	56.67
39	glslm_SmallAreaLowGrayLevelEmphasis_std	0.0065	0.65	57.32
40	ngtdm_Strength_mean	0.0060	0.60	57.92

En yüksek katkıya sahip ilk özellikler incelendiğinde, GLRLM, GLCM, GLDM ve GLSZM gibi doku temelli radyomik sınıflarının ön plana çıktığı görülmektedir. Özellikle `glrlm_ShortRunEmphasis_std` (%3.50), `glcm_SumEntropy_std` (%3.20) ve `gldm_DependenceEntropy_std` (%3.00) gibi öznitelikler, lezyon içi doku heterojenitesini ve düzensizliğini temsil eden istatistiksel ölçütler olup, iskemik dokunun mikroyapısal değişimlerini yansıtmaya açısından yüksek ayırt ediciliğe sahiptir.

İlk 10 özellik toplamda yaklaşık %23.4, ilk 20 özellik ise yaklaşık %38.0 kümülatif katkı sağlamaktadır. Bu durum, modelin karar sürecinin görece sınırlı sayıda yüksek ayırt ediciliğe sahip radyomik öznitelik tarafından yönlendirildiğini, ancak performansın yalnızca birkaç özelliğe değil, daha geniş bir özellik dağılımına dayandığını göstermektedir. İlk 40 özelliğin toplam katkısının %57.92 seviyesine ulaşması, radyomik bilginin model performansında belirleyici bir rol oynadığını ortaya koymaktadır.

Bunun yanı sıra, first-order istatistikler (ör. Skewness, Kurtosis, Entropy, Percentile ölçütleri) ile şekil tabanlı özniteliklerin (ör. Perimeter, MaximumDiameter) de anlamlı katkılar sunduğu gözlemlenmiştir. Bu bulgu, yalnızca doku heterojenitesinin değil, aynı zamanda lezyonun yoğunluk dağılımı ve geometrik özelliklerinin de mortalite sınıflandırmasında önemli olduğunu göstermektedir.

Özellikle standart sapma (std) ve ortalama (mean) temelli özniteliklerin baskınlığı, lezyon içi değişkenliğin ve mekânsal düzensizliğin model tarafından güçlü ayırt edici sinyaller olarak değerlendirildiğini düşündürmektedir. Bu durum, iskemik hasarın homojen olmayan doğasıyla klinik olarak da tutarlıdır.

Sonuç olarak, bu analiz, radyomik özelliklerin bilinçli seçimi ve modele entegre edilmesinin, sınırlı örneklemlili ve dengesiz veri kümelerinde dahi transformatör tabanlı mimarilerin performansını anlamlı ölçüde artırabildiğini göstermektedir. Elde edilen bulgular, radyomik–derin öğrenme entegrasyonunun bu tez kapsamındaki temel metodolojik dayanaklardan birini oluşturduğunu ortaya koymaktadır.

3.2 Eğitim ve Doğrulama

CPAİSD veri kümesi 112 hastanın radyolojik görüntülerinden oluşmaktadır. Veri kümesi hastaların ölüm oranı durumuna göre iki sınıfa ayrılmıştır.

Tablo 3.2. Veri kümesi sınıf dağılımları

Ölüm Oranı	Negatif	Pozitif	Toplam
Hasta dağılımı	87	25	112

Tablo 3.2, veri kümesinin sınıflar arasında önemli bir dengesizliğe ve transformatör tabanlı bir mimari için çok az sayıda örneğe sahip olduğunu göstermektedir. Dengesiz veri kümelerinde, pozitif sınıfı ve modelin gerçekten pozitif örneklerden kaçını doğru bir şekilde tahmin ettiği özellikle önemlidir. Bu nedenle, bu çalışmada kesinlik (precision) ve duyarlılık (recall) metrikleri öncelikli tercih edilecektir. Kesinlik ve duyarlılık arasında bir denge sağlamak performansın dengeli olduğunu göstereceğinden, F1 skoru ve ROC AUG metrikleri de modelin genel doğruluğunu özetlemek için çalışmada dikkate alınacaktır.

Performans Metriklerinin Hesaplamaları

1. **Doğruluk (Accuracy) :** Doğruluk, modelin tüm örnekler arasında doğru sınıflandırdığı örneklerin oranını ölçer.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

2. **Kesinlik (Precision) :** Kesinlik, modelin pozitif olarak sınıflandırdığı örneklerden ne kadarının gerçekten pozitif olduğunu ölçer.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.2)$$

3. **Duyarlılık (Recall) :** Duyarlılık, gerçek pozitif örneklerden ne kadarının doğru tespit edildiğini ölçer.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3.3)$$

4. **F1 Skoru :** F1 skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır ve dengeli performansın bir ölçüsüdür.

$$F1 \text{ Skoru} = 2 \cdot \frac{\text{Kesinlik} \cdot \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.4)$$

5. **ROC AUC** : ROC AUC, modelin sınıflandırma yeteneğini farklı eşik değerlerinde değerlendirir.

$$ROC \text{ AUC} = \int_0^1 TPR(FPR) dFPR \quad (3.5)$$

3.3 Başarılar ve Karşılaştırmalar

Bu aşamada, kayıp fonksiyonundan elde edilen veriler, dikkat mekanizmaları ve transformatör modelinin performansını artırmak için uygulanan çapraz doğrulama teknikleri ve bunların karşılaştırmaları tartışılmaktadır.

Standart kayıp fonksiyonu (BCEWithLogic) ile RT modelinin kullanılmasından sonra elde edilen performans sonuçları Tablo 3.3 ile sınıf bazında karşılaştırılmakta ve Focal Loss kullanılarak elde edilen performans sonuçları Tablo 3.4 ile karşılaştırılmaktadır.

Performans değerlendirmesi kesinlik, duyarlılık ve F1 skoru metriklerine göre yapılmaktadır. Tablo 3.3 de verilen sonuçlar sırası ile (3.2), (3.3), (3.4) eşitlikleri yardımıyla hesaplanmıştır.

Tablo 3.3. RT model performansı

Metrik	Kesinlik	Duyarlılık	F1 skoru
Negatif Sınıf	0,52	0,76	0,62
Pozitif Sınıf	0,55	0,30	0,39

Tablo 3.3’de sunulan performans metrikleri, RT modelinin iskemik inme ölüm oranı tahmini için NCCT görüntülerinden elde edilen 40 radyomik özellik üzerindeki başarımını sınıflandırma bağlamında değerlendirmektedir.

Kesinlik, modelin pozitif tahminlerinin doğruluğunu ifade eder. Negatif sınıfta kesinlik 0.52, pozitif sınıfta ise 0.55 olarak ölçülmüştür; bu, her iki sınıf için

de orta düzey bir doğruluk sunarak yanlış pozitif tahminlerin varlığını işaret etmektedir.

Duyarlılık, gerçek pozitif vakaların ne kadarının yakalandığını gösterir. Negatif sınıfta 0.76 gibi yüksek bir duyarlılık değeri, modelin ölümcül olmayan vakaları tespit etmede başarılı olduğunu ortaya koyarken, pozitif sınıfta 0.30 gibi düşük bir duyarlılık, ölümcül vakaların büyük ölçüde kaçırıldığını göstermektedir.

F1 skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak, negatif sınıfta 0.62 (orta-iyi) ve pozitif sınıfta 0.39 (düşük) değerleriyle modelin pozitif sınıfta performansının sınırlı kaldığını doğrulamaktadır.

Negatif sınıf performansı, veri kümesindeki dengesiz dağılımdan etkilenerek daha yüksek bir başarı göstermektedir; bu, negatif sınıfın daha fazla örnek içermesi nedeniyle modelin bu sınıfta daha iyi öğrenme gerçekleştirdiğini yansıtmaktadır. Ancak, pozitif sınıfın düşük duyarlılığı (0.30) ve F1 skoru (0.39), modelin ölümcül vakaları tespit etmede zorlandığını ortaya koymaktadır. Bu, klinik açıdan ciddi bir sınırlılık teşkil eder, zira ölüm oranı tahmini inme yönetiminde kritik öneme sahiptir ve düşük duyarlılık, yanlış negatiflerin yüksek olduğunu ima eder. Bu durum, veri kümesinin küçük boyutu (112 hasta) ve NCCT'nin erken iskemik değişikliklerdeki düşük hassasiyetinden (%20-40) kaynaklanmaktadır (Gonzalez, 2018). Tablo 3.4 de verilen sonuçlar sırası ile (3.2), (3.3), (3.4) eşitlikleri yardımıyla hesaplanmıştır.

Tablo 3.4. Focal loss ile model performansı

Metrik	Kesinlik	Duyarlılık	F1 skoru
Negatif Sınıf	0,62	0,55	0,58
Pozitif Sınıf	0,60	0,66	0,63

Focal Loss kullanımıyla pozitif sınıfın duyarlılık değeri 0,30'dan 0,66'ya, F1 skoru ise 0,39'dan 0,63'e yükselerek pozitif sınıfın tanımlanmasında önemli bir iyileşme sağlanmıştır. Negatif sınıfta ise hassasiyette (0,52'den 0,62'ye) bir artış gözlenmiş ancak duyarlılık değeri bir miktar azalmıştır.

Literatürde, benzer dengesiz veri kümelerinde transformatör modellerinin performans düşüklüğü raporlanmıştır. Ancak dengesiz sınıf dağılımlarında pozitif

sınıf performansının sınırlı kalması, bu çalışmada SMOTE ve focal loss gibi stratejilerin birlikte kullanılmasının temel motivasyonunu oluşturmuştur. Bu iyileşme, SMOTE ve focal loss kullanımının katkısını göstermekle birlikte, pozitif sınıf performansının hala optimize edilmesi gerektiğini vurgular.

Sonuç olarak Focal Loss kullanımı dengesiz veri kümelerinde modelin pozitif sınıf performansını önemli ölçüde artırmış ve modelin genel dengeleme yeteneğini geliştirmiştir. Bu bulgular Focal Loss fonksiyonunun özellikle zor sınıfların tanımlanmasında etkili bir çözüm sağladığını göstermektedir.

Tablo 3.5. Çapraz doğrulama metrikleri

Kat	1	2	3	4	5	Bileşik Model
Doğruluk	0,61	0,61	0,63	0,62	0,62	0,62
Kesinlik	0,59	0,58	0,61	0,59	0,61	0,60
Duyarlılık	0,73	0,75	0,72	0,76	0,69	0,73
F1-skoru	0,65	0,66	0,66	0,66	0,65	0,66
ROC AUC	0,66	0,66	0,67	0,67	0,67	0,66

Modelin genel doğruluğunu ve güvenilirliğini artırmak için çapraz doğrulama kullanılmıştır. Her kat ile ayrı ayrı eğitilen modelin tahminleri, ortalama alma yöntemi kullanılarak birleştirilmiştir.

Bu modelin geliştirilmiş (bileşik) sonuçları Tablo 3.4'te verilmiştir. Tablo 3.5 de verilen sonuçlar sırası ile (3.1), (3.2) , (3.3), (3.4), (3.5) eşitlikleri yardımıyla hesaplanmıştır. Tablo 3.5'teki performans ölçütlerine dayalı en başarılı katlama çıktısının ROC eğrisi Şekil 3.2'de verilmiştir.

Tablo 3.5 de RT modelinin 5 katlı çapraz doğrulama sonuçlarını sunarak modelin genelleme kapasitesini değerlendirmektedir.

Doğruluk katlamalar arasında 0.61-0.63 aralığında değişmiş, ensemble performansı 0.62 olarak ölçülmüştür; bu, modelin orta düzey bir sınıflandırma başarısı sunduğunu gösterir.

Kesinlik 0.58-0.61 arasında, ensemble'da 0.60'tır; bu, yanlış pozitif tahminlerin varlığını ve ölüm oranı tahmini için sınırlı hassasiyeti işaret eder.

Duyarlılık 0.69-0.76 aralığında, ensemble'da 0.73'tür; özellikle Kat 4'te 0.76 ile en yüksek, Kat 5'te 0.69 ile en düşük değer gözlenmiştir, bu da veri bölünmesindeki rastgeleliğin performans üzerindeki etkisini yansıtmaktadır.

F1 skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak 0.65-0.66 aralığında sabit kalmış, ensemble'da 0.66'dır. ROC AUC değerleri katlamalarda 0.66-0.67 arasında değişmiş, ensemble'da 0.66 olarak ölçülmüştür.


Katlamalar arası küçük varyans (örn. ROC AUC 0.66-0.67), modelin genelleme kapasitesinin tutarlı olduğunu desteklerken, küçük veri kümesi (112 hasta) nedeniyle varyans sınırlı kalmıştır. Ensemble performansı (0.62 doğruluk, 0.66 F1 skoru, 0.66 ROC AUC), katlamaların ortalamasına yakın olup modelin stabil olduğu söylenebilir.

Focal Loss ve çapraz doğrulama süreçlerinin performans üzerindeki etkisi pozitif olmasına rağmen, Tablo 3.4'te her iki sınıf için performans ölçütlerinin iyileştirilmesi gerektiği ve Tablo 3.5'te ensemble modelinin genel çıktısının artırılması gerektiği görülmektedir.

Ayrıca, Şekil 3.2 incelendiğinde, modelin pozitif sınıfı yakalamada kazandığı yetenek geliştirilme gerekliliği ile beraber başarılı olduğunda göstermektedir.

Yanlış pozitiflerin yüksek olması kesinlik değerini (%60,50) düşürmektedir. F1 skoru (%66,00) da modelin dengeli bir performans gösterdiğini ancak yine de geliştirilebileceğini göstermektedir.

Literatüre kazandırılan, Strokeformer modeli ile attention mekanizmalarının prognostik tahmin başarısını artırabildiği görülmektedir (Cao vd., 2025). Bu nedenle modele farklı dikkat mekanizmaları uygulanmıştır.



Şekil 3.2. En başarılı parametrelerin ROC eğrisi

Tablo 3.6, Multi Head Attention ve Simple Attention mekanizmalarının performansa katkılarını göstermektedir. Tablo 3.6 de verilen metrikler sırası ile (3.1), (3.2), (3.3), (3.4), (3.5) eşitlikleri ve Simple Attention mekanizması (2.1), eşitliği yardımı ile hesaplanmıştır.

Tablo 3.6. Dikkat mekanizmalarının karşılaştırılması

Metrik	Doğruluk	Kesinlik	Duyarlılık	F1 skoru	ROC AUC
Multi Head Attention	0,5944	0,5794	0,6889	0,6294	0,6459
Simple Attention	0,6889	0,6932	0,6778	0,6854	0,7167

Tablo 3.6, RT modelinde Simple Attention ve Multi-Head Attention mekanizmalarının performanslarını karşılaştırmaktadır.

Doğruluk, doğru tahminlerin oranı olarak hesaplanmış; Simple Attention 0.69 ile Multi-Head Attention'a (0.59) kıyasla yaklaşık %9 daha yüksek bir başarı sunarak genel sınıflandırma performansında belirgin bir iyileşme sağlamıştır.

Kesinlik, pozitif tahminlerin doğruluğunu ölçer; Simple Attention 0.69 ile yanlış pozitifleri daha iyi azaltarak ölüm oranı tahmininde daha hassas bir performans sergilerken, Multi-Head Attention 0.58 ile sınırlı kalmıştır.

Duyarlılık, gerçek pozitiflerin yakalanma oranı olarak hesaplanmıştır; Multi-Head Attention 0.69 ile Simple Attention'a (0.68) kıyasla %1.1'lik minimal bir avantaj sağlamış, ancak bu fark klinik açıdan belirleyici değildir.

F1 skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak Simple Attention'da 0.69, Multi-Head Attention'da 0.63 ölçülmüş; Simple Attention, dengeli performans ölçütünde %5.6 daha yüksek başarı göstermiştir.

ROC AUC, genel sınıflandırma başarısını değerlendirir; Simple Attention 0.72 ile Multi-Head Attention'a (0.65) göre %7 daha yüksek bir genelleme kapasitesi sunmuştur.

Simple Attention'ın üstünlüğü, küçük ve dengesiz veri kümesinde daha etkili olduğunu ortaya koymaktadır. Focal loss ile desteklenen Simple Attention, azınlık sınıfına odaklanmayı iyileştirerek ROC AUC'yi 0.7167'ye çıkarmıştır.

Buna karşılık, Multi-Head Attention, karmaşık veri ilişkilerini yakalamada avantajlı olmasına rağmen, veri boyutunun yetersizliği nedeniyle overfitting'e yatkınlık göstermiş; duyarlılık'ta (0.69) Simple Attention'a yakın bir performans sunarken, düşük kesinlik (0.58) ve ROC AUC (0.65) ile yanlış pozitiflerin yüksek olduğu gözlenmiştir. NCCT'nin erken iskemik değişikliklerdeki düşük hassasiyeti (%20-40), radyomik özelliklerin kalitesini etkileyerek Multi-Head Attention'ın genelleme kapasitesini sınırlamış olabilir.

Tablo 3.6, Simple Attention mekanizmasının özellikle genel doğruluk ve sınıflandırma eşiği değişse bile pozitif ve negatif sınıfları ayırt etme yeteneği ROC AUC açısından üstün olduğunu göstermektedir. Öte yandan, Multi-Head Attention mekanizması pozitif sınıfları yakalama yeteneği (recall) bakımından benzer bir performans sergilese de diğer metriklerde geride kalmıştır. Simple Attention'ın yüksek kesinlik ve ROC AUC değerleri, klinik ölüm oranı tahmini için daha güvenilir bir model sunarken, duyarlılıktaki küçük fark, pozitif sınıfın tespitinde ek optimizasyon gerekliliğini göstermektedir.

3.4 Makine Öğrenimi Modelleri ile Karşılaştırma

Transformatör gibi verileri hızlı bir şekilde işleyebilen modeller, inme sonrası beyin hasarını en aza indirmek ve klinisyenleri hastanın iyileşmesini sağlayabilecek acil müdahalelere yönlendirmek açısından oldukça önemlidir (Samak vd., 2025; Yopianga vd., 2024). Bu nedenle, doğru tanıyı sağlamak için bu aşamada modeller arasında karşılaştırmalar ele alınmıştır. DL mimarimiz RT modeline kıyasla ML modelleri olarak Random Forest (Breiman, 2001; Hastie vd., 2009), XGBoost (Chen ve Guestrin, 2016; Wade, 2020), SVM (Cortes ve Vapnik, 1995; Steinwart ve Christmann, 2008) ve Lojistik Regresyon (Hastie vd., 2009; Hosmer vd., 2013) algoritmaları tercih edilmiştir.

ML modeller veri bölme stratejisi ve doğrulama prosedürü açısından RT modeliyle aynı koşullarda, dikkatle seçilmiş hiperparametrelerle eğitilmiş ve aynı örneklerle test edilmiştir.

Model ayarları deneysel denemelerin yanı sıra literatürde önerilen hiperparametre aralıkları doğrultusunda yapılandırılmıştır (Demircioğlu, 2024; Kolossváry vd., 2017; Tsai vd., 2022; Warkentin vd., 2023). Her bir model için kullanılan hiperparametreler Tablo 3.7'de verilmiştir. Özellikle Random Forest ve XGBoost için kullanılan değerler, akademik çalışmalarda önerilen aralıklarla örtüşmekte ve bu modeller, literatürde radyomik tabanlı sınıflandırmalarda başarılı sonuçları ile öne çıkmaktadır (Corso vd., 2021).

Sınıf dengesizliğini gidermek amacıyla tüm modellerde dengeli sınıf ağırlığı (`class_weight='balanced'`) parametresi kullanılmıştır.

Tüm modellerin değerlendirilmesinde 5 katlı çapraz doğrulama yöntemi uygulanmış ve bu sayede her bir modelin genelleme kapasitesi objektif biçimde ölçülmüştür. Bu doğrultuda DL mimarimiz RT modelinin ve ML modellerinin test aşamasındaki performans ölçütleri Tablo 3.8'de karşılaştırılmış ve Şekil 3.3'de görselleştirilmiştir.

Tablo 3.8 de verilen sonuçlar sırası ile (3.1), (3.2), (3.3), (3.4), (3.5) eşitlikleri yardımıyla hesaplanmıştır.

Tablo 3.7. ML modellerin hiperparametre ayarları

Model	Hiperparametre	Literatürdeki Aralıklar	Çalışma Değerleri
Random Forest	n_estimators	50 – 1000	200
	max_depth	1-20	15
	min_samples_split	2 – 10	5
	min_samples_leaf	1 – 5	2
	class_weight	'balanced', None	balanced
XGBoost	n_estimators	50-1000	200
	max_depth	1-13	8
	learning_rate	0.01 – 0.15	0.05
	subsample	0.6 – 1.0	0.8
	colsample_bytree	0.6 – 1.0	0.8
	scale_pos_weight	0.5 – 2	1.0
SVM	kernel	'rbf', 'linear', 'poly'	rbf
	c	0.01 – 100	1.0
	gamma	'scale', 'auto',	'scale'
	class_weight	'balanced', None	balanced
Logistic Regresion	c	0.01 – 1000	1.0
	max_iter	100 – 1000	1000
	class_weight	'balanced', None	balanced

Tablo 3.8. ML modellerin performans karşılaştırmaları

Model	Doğruluk	Kesinlik	Duyarlılık	F1 skoru	ROC AUC
Random Forest	0,5420	0,5772	0,3140	0,4067	0,5676
XGBoost	0,4835	0,4758	0,3250	0,3862	0,5604
SVM	0,4890	0,4784	0,2440	0,3232	0,4310
Logistic Regresion	0,3460	0,2941	0,2200	0,2517	0,3132

Tablo 3.8, RT modelini Random Forest, XGBoost, SVM ve Lojistik Regresyon ile karşılaştırarak iskemik inme ölüm oranı tahmini performanslarını değerlendirmektedir.

Random Forest, geleneksel modeller arasında en iyi performansı sergilemiş (ROC AUC 0.57), ancak düşük duyarlılık (0.31) pozitif sınıfı yakalamada ciddi sınırlılıklar gösterir. Ensemble yapısı, dengesiz veri kümesinde avantaj sağlasa da, NCCT'nin erken iskemik değişikliklerdeki düşük hassasiyeti performansı kısıtlamıştır (Gonzalez, 2018, 2024).


XGBoost, Random Forest'a yakın bir performans sunmuş (ROC AUC 0.56), ancak düşük duyarlılık ve kesinlik, gradient boosting'in küçük veri kümesinde overfitting'e yatkın olduğunu gösterir (Chen ve Guestrin, 2016).

SVM, düşük duyarlılık ve ROC AUC (0.43) ile zayıf kalmış; kernellerin dengesiz veri ve küçük örnek sayısında başarısız olduğu gözlenmiştir (Cortes ve Vapnik, 1995).

Lojistik Regresyon, en zayıf performansı (ROC AUC 0.31) göstermiş; doğrusal yapısı, karmaşık radyomik özellik ilişkilerini yakalayamamıştır (Hastie vd., 2009).

RT, Simple Attention ve focal loss ile tüm geleneksel modellere üstünlük sağlamış; ROC AUC'de %15 (Random Forest'a göre) ila %40 (Lojistik Regresyon'a göre) daha iyi performans sunarak tezin yenilikçi katkısını desteklemiştir.

NCCT'nin düşük hassasiyeti, geleneksel modellerin başarısını kısıtlarken, RT'nin genelleme kapasitesi Simple Attention ile artmıştır. Geleneksel modellerin düşük duyarlılıkları, ölüm oranı tahmini için klinik güvenilirliklerini sınırlandırırken, RT daha güvenilir ve umut verici bir model sunar. Şekil 3.3 modellerin performanslarını bar grafiğiyle görselleştirir.



Şekil 3.3. Makine öğrenimi modelleri ve tranformatör modelinin performans karşılaştırmaları

Modelimiz tüm ölçütlerde diğer modellere kıyasla performans avantajı göstermektedir.

Random Forest, ML öğrenme modelleri arasında en iyi performansı göstermektedir, ancak modelimizin çok gerisinde kalmaktadır.


Özellikle SVM ve Lojistik Regresyon modelleri hem doğruluk hem de ayırım gücü açısından zayıf sonuçlar vermiştir. Ayrıca diğer tüm modeller eğitim aşamasında aşırı öğrenme sorunları göstermektedir.

4. SONUÇ VE ÖNERİLER

Bu çalışmada, iskemik inme tanısı almış hastaların radyolojik görüntülerinden inme sonrası mortalite olasılığını sınıflandırmak amacıyla transformatör tabanlı bir derin öğrenme modeli geliştirilmiştir. Çalışma, sınırlı ve dengesiz veri kümeleriyle çalışmanın zorluklarını açıkça ortaya koymaktadır. Özellikle küçük örneklem boyutu ve ölümcül/ölümcül olmayan sınıflar arasındaki yüksek dengesizlik, geleneksel ML modellerinin genel performansını olumsuz etkilemiştir.

Buna karşın, önerilen DL tabanlı model, sınıf dengesizliğine ve düşük örneklem büyüklüğüne rağmen istikrarlı ve yüksek performans göstermiştir. Bu başarı, modelin yüksek boyutlu özellikleri öğrenme kapasitesi ve karmaşık desenleri yakalama yeteneği ile açıklanabilir. Bu durum, sınırlı veriye sahip sağlık veri kümelerinde dahi dikkatli biçimde tasarlanan DL yöntemlerinin klasik makine öğrenmesi yaklaşımlarına güçlü bir alternatif oluşturabileceğini ortaya koymaktadır.

Şekil 4.1’de sunulan ROC eğrisi karşılaştırmaları, klasik ML modellerinin bu sınıflandırma problemi için yetersiz kaldığını göstermektedir.



Şekil 4.1. İnme sınıflama modellerinin ROC eğrilerinin karşılaştırılması

Farkların büyüklüğü, modeller arasında istatistiksel olarak anlamlı farklılıklar olabileceğine işaret etmektedir; ancak bu çalışma kapsamında modeller arası istatistiksel anlamlılık testleri uygulanmamıştır.

Bulgular betimsel karşılaştırmalar şeklinde sunulmuş olup, ilerleyen çalışmalarda kat bazlı p-değerlerinin hesaplanması planlanmaktadır.

RT modeli, Simple Attention mekanizması ve focal loss fonksiyonu sayesinde geleneksel tüm modelleri geride bırakmış; Random Forest'a kıyasla %15, Lojistik Regresyon'a göre ise %40 daha yüksek ROC AUC değeri elde etmiştir. Bu sonuç, önerilen modelin literatüre özgün bir katkı sunduğunu göstermektedir. SMOTE ve interpolasyon tabanlı veri artırma yaklaşımı, dengesiz veri problemine etkili bir çözüm sağlamış ve modelin genelleme kabiliyetini artırmıştır. Ayrıca, önerilen modelin dikkat mekanizması sayesinde radyomik öznitelikler arasındaki uzun menzilli ilişkileri yakalayabilmesi, erken dönem iskemik değişimlerin mortalite üzerindeki etkilerinin daha doğru biçimde temsil edilmesini sağlamıştır.

Çalışmanın sınırlılıkları arasında veri kümesinin sınırlı örneklem büyüklüğüne sahip olması ve sınıf dağılımındaki dengesizlik öncelikli olarak öne çıkmaktadır. Bunun yanı sıra, transformatör modelinin yüksek veri boyutlarına ihtiyaç duyması da bir diğer sınırlılık olarak değerlendirilmektedir.

Gelecek çalışmalarda, elde edilen başarının daha ileri taşınabilmesi amacıyla, farklı dikkat mekanizmaları Jiang vd. (2025) ile Wakamatsu ve Ono (2024) tarafından önerilen geliştirilmiş kayıp fonksiyonlarını bir araya getiren hibrit mimarilere odaklanılması önerilmektedir. Bunun yanı sıra, veri artırma, transfer öğrenme ve örnek ağırlıklandırma gibi stratejilerin entegre edilmesi, sınıf dengesizliği probleminin aşılmasına yönelik ek kazanımlar sağlayabilir.

Ayrıca, çok merkezli ve daha geniş ölçekli veri kümeleri üzerinde gerçekleştirilecek çalışmaların, geliştirilen modelin genelleştirilebilirliğini ve potansiyel klinik geçerliliğini daha güvenilir biçimde değerlendirmeye olanak tanıyacağı öngörülmektedir.

Bu çalışmada, düşük işlem maliyetini korumak amacıyla model mimarisi bilinçli olarak hibrit bir yapıya dönüştürülmemiş; bu doğrultuda performans değerleri izlenmiştir. Ancak literatürdeki bulgular ışığında, hibrit mimarilerin kullanılmasıyla daha yüksek performans seviyelerine ulaşılabileceği değerlendirilmektedir. Bu tür geniş ölçekli araştırmalar, geliştirilen modelin klinik karar destek sistemlerine entegrasyon potansiyelini değerlendirmek açısından da kritik öneme sahiptir.

KAYNAKLAR

- Abbaoui, W., Retal, S., Ziti, S., & El Bhiri, B. (2024). Automated ischemic stroke classification from MRI scans: Using a vision transformer approach. *Journal of Clinical Medicine*, 13(8), 2323. <https://doi.org/10.3390/jcm13082323>
- American Heart Association Council on Epidemiology and Prevention Statistics Committee and Stroke Statistics Committee. (2025). 2025 heart disease and stroke statistics: A report of US and global data from the American Heart Association. *Circulation*, 151(8), e41–e660. <https://doi.org/10.1161/CIR.0000000000001303>
- Ayoub, M., Liao, Z., Hussain, S., Li, L., Zhang, C. W. J., & Wong, K. K. L. (2023). End-to-end vision transformer architecture for brain stroke assessment based on multi-slice classification and localization using computed tomography. *Computerized Medical Imaging and Graphics*, 109, 102294. <https://doi.org/10.1016/j.compmedimag.2023.102294>
- Birnbaum, L., Sanelli, P., & Naidich, T. P. (2018). Stroke imaging. In StatPearls. NCBI Bookshelf. <https://www.ncbi.nlm.nih.gov/books/NBK557824/>
- Bivard, A., Levi, C., Lin, L., & Parsons, M. W. (2020). MRI versus CT for acute ischemic stroke: A systematic review and meta-analysis. *Journal of Cerebral Blood Flow & Metabolism*, 40(9), 1781–1795. <https://doi.org/10.1177/0271678X20928012>
- Bivard, A., Levi, C., Spratt, N., Parsons, M., & Miteff, F. (2023). Neuroimaging modalities used for ischemic stroke. *Frontiers in Neurology*, 14, 1089123. <https://doi.org/10.3389/fneur.2023.1089123>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Cao, M., Jin, H., Wang, Y., Wang, L., & Ji, J. (2025). Strokeformer: A novel deep learning paradigm training transformer-based architecture for stroke prognosis prediction. *PLoS ONE*, 20(8), e0330530. <https://doi.org/10.1371/journal.pone.0330530>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). ACM. <https://doi.org/10.1145/2939672.2939785>
- Clarke, M. (2018). History of stroke imaging. MDPI Books. <https://doi.org/10.3390/books978-3-03897-615-8>
- Corso, F., Tini, G., Lo Presti, G., Garau, N., De Angelis, S. P., Bellerba, F., Morelli, F., Basso, S., Gnagnarella, P., Alloisio, M., Pastorino, U., & Raimondi, S. (2021). The challenge of choosing the best classification method in radiomic analyses: Recommendations and applications to lung cancer CT images. *Cancers (Basel)*, 13(12), 3088. <https://doi.org/10.3390/cancers13123088>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Demircioğlu, A. (2024). The effect of feature normalization methods in radiomics. *Insights into Imaging*, 15(1), 2. <https://doi.org/10.1186/s13244-023-01575-7>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv*, abs/2010.11929. <https://api.semanticscholar.org/CorpusID:225039882>
- Gillies, R. J., Kinahan, P. E., & Hricak, H. (2016). Radiomics: Images are more than pictures, they are data. *Radiology*, 278(2), 563–577. <https://doi.org/10.1148/radiol.2015151169>

- Gonzalez, R. G. (2018). Acute ischemic stroke imaging. *Stroke*, 49(2), 388–395. <https://doi.org/10.1161/STROKEAHA.117.018561>
- Gonzalez, R. G. (2024). Ischemic stroke workup. Medscape. <https://emedicine.medscape.com/article/1916852-overview>
- Hassan, A. E., Rabinstein, A. A., & El-Ghanem, M. (2021). Role of imaging in early diagnosis of acute ischemic stroke. *Egyptian Journal of Neurology, Psychiatry and Neurosurgery*, 57(1), 114. <https://doi.org/10.1186/s41983-021-00374-9>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: Data mining, inference, and prediction (2nd ed.). Springer. <https://web.stanford.edu/~hastie/ElemStatLearn/>
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (3rd ed.). John Wiley & Sons. <https://doi.org/10.1002/9781118548387>
- Hounsfield, G. N. (1973). Computerized transverse axial scanning (tomography): Part 1. Description of system. *British Journal of Radiology*, 46(552), 1016–1022. <https://doi.org/10.1259/0007-1285-46-552-1016>
- Huang, T., Li, W., Zhou, Y., Zhong, W., & Zhou, Z. (2024). Can the radiomics features of intracranial aneurysms predict the prognosis of aneurysmal subarachnoid hemorrhage? *Frontiers in Neuroscience*, 18, 1446784. <https://doi.org/10.3389/fnins.2024.1446784>
- Jiang, L., Hu, J., & Huang, T. (2025). Improved SwinUNet with fusion transformer and large kernel convolutional attention for liver and tumor segmentation in CT images. *Scientific Reports*, 15, 14286. <https://doi.org/10.1038/s41598-025-98938-5>
- Katar, O., Yildirim, O., ve Eroglu, Y. (2023). Vision transformer model for efficient stroke detection in neuroimaging. In 2023 4th International Informatics and Software Engineering Conference (IISEC) (pp. 1–6). IEEE. <https://doi.org/10.1109/IISEC59749.2023.10391051>
- Kolossváry, M., Karády, J., Szilveszter, B., Kitslaar, P., Hoffmann, U., Merkely, B., & Maurovich-Horvat, P. (2017). Radiomic features are superior to conventional quantitative computed tomographic metrics to identify coronary plaques with napkin-ring sign. *Circulation: Cardiovascular Imaging*, 10(12), e006843. <https://doi.org/10.1161/CIRCIMAGING.117.006843>
- Lambin, P., Rios-Velazquez, E., Leijenaar, R., Carvalho, S., van Stiphout, R. G. P. M., Granton, P., Zegers, C. M. L., Gillies, R., Boellard, R., Dekker, A., & Aerts, H. J. W. L. (2012). Radiomics: Extracting more information from medical images using advanced feature analysis. *Nature Reviews Clinical Oncology*, 9(3), 145–149. <https://doi.org/10.1038/nrclinonc.2011.209>
- Gomez, S., Rangel, E., Mantilla, D., Ortiz, A., Camacho, P., de la Rosa, E., Seia, J., Kirschke, J. S., Li, Y., El Habib Daho, M., & Martínez, F. (2024). APIS: A paired CT–MRI dataset for ischemic stroke segmentation—methods and challenges. *Scientific Reports*, 14, 20543. <https://doi.org/10.1038/s41598-024-71273-x>
- Li, Z., Gan, G., Guo, J., Liu, Y., Wang, X., Zhang, L., Chen, H., Zhao, Y., Wu, Q., & Ma, C. (2024). Accurate object localization facilitates automatic esophagus segmentation in deep learning. *Radiation Oncology*, 19(1), Article 55. <https://doi.org/10.1186/s13014-024-02448-z>
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollár, P. (2020). Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 318–327. <https://doi.org/10.1109/TPAMI.2018.2858826>
- Ma, D., Wang, M., Xiang, A., Qi, Z., & Yang, Q. (2024). Transformer-based classification outcome prediction for multimodal stroke treatment. In 2024 IEEE 2nd International Conference on Sensors, Electronics and Computer-Assisted Intervention (ICSECE) (pp. 383–386). IEEE. <https://doi.org/10.1109/ICSECE61636.2024.10729409>

- Maier, O., Menze, B. H., von der Gablentz, J., Häni, L., Heinrich, M. P., Liebrand, M., Winzeck, S., Bas, C., Bentley, P., Chen, L., Christiaens, D., Dutil, F., Egger, K., Feng, C., Gao, Y., Ghafoorian, M., Götz, M., Halme, H.-L., Hao, J., ... Handels, H. (2017). ISLES 2015 – A public evaluation benchmark for ischemic stroke lesion segmentation from multispectral MRI. *Medical Image Analysis*, 35, 250–269. <https://doi.org/10.1016/j.media.2016.07.009>
- McKinley, R., Meier, R., & Wiest, R. (2018). Ensembles of densely-connected CNNs with label-uncertainty for brain tumor segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2018* (pp. 456–465). Springer. https://doi.org/10.1007/978-3-030-11726-9_40
- Mérida, I., Jung, J., Bouvard, S., Le Bars, D., Lancelot, S., Lavenne, F., ... Costes, N. (2021). CERMEP-IDB-MRXFDG: A database of 37 normal adult human brain [¹⁸F]FDG PET, T1 and FLAIR MRI, and CT images available for research. *EJNMMI Research*, 11(1), 91. <https://doi.org/10.1186/s13550-021-00830-6>
- Parmar, C., Grossmann, P., Bussink, J., Lambin, P., & Aerts, H. J. W. L. (2015). Radiomic feature extraction from CT images. *PLoS ONE*, 10(12), e0143236. <https://doi.org/10.1371/journal.pone.0143236>
- Qari, S., & Thafar, M. A. (2025). Brain stroke classification using CT scans with transformer-based models and explainable AI. *Diagnostics*, 15(19), 2486. <https://doi.org/10.3390/diagnostics15192486>
- Qiu, W., Kuang, H., Wang, Y., Wu, E., Chen, J., Yu, Y., Li, Z., Zhang, Y., & Tong, X. (2023). A large public dataset of annotated clinical MRIs and stroke lesion segmentations. *Scientific Data*, 10, 546. <https://doi.org/10.1038/s41597-023-02798-1>
- Raj, R., Mathew, J., Kannath, S. K., & Rajan, J. (2023). StrokeViT with AutoML for brain stroke classification. *Engineering Applications of Artificial Intelligence*, 119, 105772. <https://doi.org/10.1016/j.engappai.2022.105772>
- Saake, M., Breuer, J., & Dörfler, A. (2025). Evolution of imaging techniques in ischemic stroke. *Stroke*, 56(2), 345–356. <https://doi.org/10.1161/STROKEAHA.124.048912>
- Samak, Z. A., Clatworthy, P., & Mirmehdi, M. (2025). Automatic prediction of stroke treatment outcomes: Latest advances and perspectives. *Biomedical Engineering Letters*. <https://doi.org/10.1007/s13534-025-00462-y>
- Smith, E. E., Saposnik, G., Biessels, G. J., & Doubal, F. N. (2023). Multimodal imaging in stroke: An update. *The Lancet Neurology*, 22(8), 711–722. [https://doi.org/10.1016/S1474-4422\(23\)00192-7](https://doi.org/10.1016/S1474-4422(23)00192-7)
- Steinwart, I., & Christmann, A. (2008). Support vector machines. Springer. <https://doi.org/10.1007/978-0-387-77242-4>
- Tang, G., Du, L., Ling, S., Che, Y., & Chen, X. (2024). Multi-type classification of lung nodules based on CT radiomics and ensemble learning for diversity weighting. *Quantitative Imaging in Medicine and Surgery*, 14(12), 8942–8965. <https://doi.org/10.21037/qims-24-1315>
- Tsai, Y.-L., Chen, S.-W., Kao, C.-H., & Cheng, D.-C. (2022). Neck lymph node recurrence in HNC patients might be predicted before radiotherapy using radiomics extracted from CT images and XGBoost algorithm. *Journal of Personalized Medicine*, 12(9), 1377. <https://doi.org/10.3390/jpm12091377>
- Umerenkov, D., Kudin, S., Pekshev, M., & Pavlov, D. (2024). CPAISD: Core-penumbra acute ischemic stroke dataset. Zenodo. <https://doi.org/10.5281/zenodo.10892316>
- van Griethuysen, J. J. M., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., Beets-Tan, R. G. H., Fillion-Robin, J.-C., Pieper, S., & Aerts, H. J. W. L. (2017). Computational

- radiomics system to decode the radiographic phenotype. *Cancer Research*, 77(21), e104–e107. <https://doi.org/10.1158/0008-5472.CAN-17-0339>
- Vaswani, A., Shazeer, N., Parmar, N., Uszoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems* (NeurIPS) (pp. 5998–6008). <https://papers.nips.cc/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf>
- Wade, C. (2020). *Hands-on gradient boosting with XGBoost and scikit-learn: Perform accessible machine learning and extreme gradient boosting with Python*. Packt Publishing. ISBN: 9781839218354
- Wakamatsu, K., & Ono, S. (2024). TransUNet with unified focal loss for class-imbalanced semantic segmentation. *Artificial Life and Robotics*, 29, 101–106. <https://doi.org/10.1007/s10015-023-00919-2>
- Wang, Y., Tian, H., Ji, Y., & Liu, M. (2024). Full-automatic segmentation algorithm of brain tumor based on RFE-UNet and hybrid focal loss function. *Radioengineering*, 33, 253–264. <https://doi.org/10.13164/re.2024.0253>
- Warkentin, M., Chiles, D., Smith, J. A., Johnson, R. E., Lee, S., Patel, N., & Kim, H. (2023). Radiomics analysis to predict pulmonary nodule malignancy. *Thorax*, 79(4), 307–316. <https://doi.org/10.1136/thorax-2023-221300>
- Wintermark, M. (2012). Imaging of stroke: Part 1, perfusion CT—Overview of imaging technique, interpretation pearls, and common pitfalls. *American Journal of Roentgenology*, 198(1), 52–62. <https://doi.org/10.2214/AJR.10.7310>
- Wintermark, M., Sanelli, P. C., Albers, G. W., Bello, J. A., & Derdeyn, C. P. (2017). Imaging recommendations for acute stroke and transient ischemic attack patients: A joint statement by the American Society of Neuroradiology and the American College of Radiology. *RadioGraphics*, 37(6), 1840–1856. <https://doi.org/10.1148/rg.2017170030>
- Xie, H., Wang, J., Li, X., & Zhang, S. (2024). CPAISD: Core-penumbra acute ischemic stroke dataset based on non-contrast CT. *arXiv preprint arXiv:2404.02518*. <https://arxiv.org/abs/2404.02518>
- Yopiangga, A. P., Badriyah, T., Syarif, I., & Sakinah, N. (2024). Stroke disease classification using CT scan image with vision transformer method. In *2024 International Electronics Symposium (IES)* (pp. 436–441). IEEE. <https://doi.org/10.1109/IES63037.2024.10665834>
- Zafari-Ghadim, Y., Rashed, E. A., Mohamed, A., & Mabrok, M. (2024). Transformer-based architectures for stroke segmentation: A review. *Artificial Intelligence Review*, 57(11), 307. <https://doi.org/10.1007/s10462-024-10900-5>
- Zhang, H., Wu, E., Liu, J., Li, Q., & Tong, X. (2024). ISLES 2024: The first longitudinal multimodal multi-center real-world dataset in (sub-)acute stroke. *arXiv preprint arXiv:2408.11142*. <https://arxiv.org/abs/2408.11142>
- Zhang, J., Wang, L., & Chen, Y. (2020). Transformers for medical image segmentation: A review. *Medical Image Analysis*, 67, 101874. <https://doi.org/10.1016/j.media.2020.101874>
- Zhang, W., Guo, Y., & Jin, Q. (2023). Radiomics and its feature selection: A review. *Symmetry*, 15(10), 1834. <https://doi.org/10.3390/sym15101834>