



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**BİLGİSAYARLI TOMOGRAFİ
GÖRÜNTÜLERİNDE İNMENİN FARKLI
DERİN ÖĞRENME MODELLERİ İLE
SINIFLANDIRILMASI**

Mustafa ALTINTAŞ

YÜKSEK LİSANS TEZİ

Biyomedikal Mühendisliği Anabilim Dalı

**Temmuz - 2021
KONYA
Her Hakkı Saklıdır**

ÖZET

YÜKSEK LİSANS TEZİ

BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE İNMENİN FARKLI DERİN ÖĞRENME MODELLERİ İLE SINIFLANDIRILMASI

Mustafa ALTINTAŞ

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğretim Üyesi Muhammet Üsame ÖZİÇ

2021, 111 Sayfa

Jüri

**Dr. Öğretim Üyesi Muhammet Üsame ÖZİÇ
Dr. Öğretim Üyesi Mücahid BARSTUĞAN
Dr. Öğretim Üyesi Kemal ÇETİN**

İnme hastalığı beyin damarlarında tıkanma ve kan akışının azalması durumunda meydana gelen nörolojik bir vakadır. Damarların beslemiş olduğu beyin hücreleri yetersiz oksijen ve besinden dolayı hızlı bir şekilde ölmeye başlar. İnmenin meydana geldiği bu bölgelerin yönettiği fonksiyonlarda kalıcı veya geçici hasarlar meydana gelmektedir. Bundan dolayı inme başladığı anda hızlı ve erken müdahale beyin hasarının en az kayıpla atlatılabilmesi için çok önemlidir. Geç müdahale durumunda hastanın ömür boyu maruz kalacağı sakatlıklar oluşabilir. Klinikte en çok görülen inme çeşitleri iskemik ve hemorajik inmedir. İnme çeşitleri bir medikal görüntüleme tekniği olan bilgisayarlı tomografi ile tanı almaktadır. Bu tez çalışmasında, uluslararası veri tabanlarından alınan iskemik inme, hemorajik inme ve normal bilgisayarlı tomografi görüntüleri kullanarak hastalığı sınıflandıran derin öğrenme modellerinin performansları araştırılmıştır. AlexNet, ResNet, GoogleNet, InceptionV3, ShuffleNet, SqueezeNet derin öğrenme modelleri transfer öğrenme yöntemi kullanılarak bilgisayarlı tomografi görüntüleri ile eğitilmiş ve performans kriterleri hesaplanmıştır. Veriler %80 eğitim %20 test olarak ayrılmış, eğitim ve test işlemlerinde beş kat çapraz geçiş kullanılmıştır. Üç sınıflı çıkış için en yüksek sonuçlar AlexNet ile 0.9086 ± 0.02 hassasiyet, 0.9097 ± 0.02 duyarlılık, 0.9091 ± 0.02 F1 Puanı, 0.9089 ± 0.02 doğruluk, 21 dakika 37 saniyelik işlem süresi olarak bulunmuştur.

Anahtar Kelimeler: Derin öğrenme, Hemorajik inme, İskemik inme, Sınıflandırma, Stroke, Transfer öğrenme

ABSTRACT

MS THESIS

CLASSIFICATION OF STROKE WITH DIFFERENT DEEP LEARNING MODELS IN COMPUTERIZED TOMOGRAPHY IMAGES

Mustafa ALTINTAŞ

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN BIOMEDICAL ENGINEERING

Advisor: Assist. Prof. Dr. Muhammet Üsâme ÖZİÇ

2021, 111 Pages

Jury

Assist. Prof. Dr. Muhammet Üsâme ÖZİÇ

Assist. Prof. Dr. Mücahid BARSTUĞAN

Assist. Prof. Dr. Kemal ÇETİN

Stroke is a neurological case that occurs when cerebral vessels become blocked and blood flow is reduced. Brain cells fed by the vessels begin to die rapidly due to insufficient oxygen and nutrients. Permanent or temporary damage occurs in the functions managed by these regions where the stroke occurs. Therefore, prompt and early intervention at the onset of stroke is very important in order to overcome the brain damage with minimum loss. In case of late intervention, disability to which the patient will be exposed for life may occur. The most common types of stroke in the clinic are ischemic and hemorrhagic stroke. Stroke types are diagnosed by computerized tomography, a medical imaging technique. In this thesis, the performance of deep learning models that classify the disease using ischemic stroke, hemorrhagic stroke and normal computed tomography images taken from international databases were investigated. Alexnet, ResNet, GoogleNet, InceptionV3, ShuffleNet, SqueezeNet deep learning models were trained with computerized tomography images using transfer learning method and performance criteria were calculated. The data were separated as 80% training and 20% testing, and five-fold cross-validation was used in training and testing processes. The highest results for the three-class output were found with AlexNet as 0.9086±0.02 precision, 0.9097±0.02 sensitivity, 0.9091±0.02 F1 Score, 0.9089±0.02 accuracy, 21 minutes 37 seconds processing time.

Keywords: Classification, Deep learning, Hemorrhagic stroke, Ischemic stroke, Stroke, Transfer learning

ÖNSÖZ

Bu tez çalışmasında hazırlanmasında; kaliteli eğitim vererek, öncü ve güncel yaklaşımlara yönlendirerek, motivasyonumuzu hep yüksekte tutarak desteklerini esirgemeyen danışmanım Dr. Öğretim Üyesi Muhammet Üsâme ÖZİÇ'e, değerli bilgileriyle bizleri aydınlatan bölüm başkanımız Prof. Ahmet AVCI'ya teşekkürlerimi sunarım. Yine, tezi hazırlarken yanlarında daha az vakit geçirdiğim, anlayışla karşılayıp destek olan kıymetli eşim, annem, babam, kardeşlerime özel teşekkür ederim.

Mustafa ALTINTAŞ
KONYA-2021



İÇİNDEKİLER

| | |
|--|------------|
| ÖZET | ii |
| ABSTRACT..... | iii |
| ÖNSÖZ | iv |
| İÇİNDEKİLER | v |
| SİMGELER VE KISALTMALAR | vii |
| 1. GİRİŞ | 1 |
| 2. KAYNAK ARAŞTIRMASI | 3 |
| 3. MATERYAL VE YÖNTEM..... | 19 |
| 3.1. İnme | 19 |
| 3.1.1. İskemik inme..... | 20 |
| 3.1.2. Hemorajik inme | 21 |
| 3.2. Bilgisayarlı Tomografi..... | 22 |
| 3.3. Veri Tabanları | 24 |
| 3.3.1. ISLES 2018..... | 24 |
| 3.3.2. RSNA 2019..... | 26 |
| 3.4. Derin Öğrenme..... | 27 |
| 3.4.1. Yapay sinir ağları..... | 28 |
| 3.4.2. Evrişimli sinir ağ yapısı ve mimarisi | 32 |
| 3.4.3. AlexNet..... | 37 |
| 3.4.4. ResNet..... | 38 |
| 3.4.5. GoogLeNet..... | 38 |
| 3.4.6. InceptionV3..... | 39 |
| 3.4.7. ShuffleNet | 40 |
| 3.4.8. SqueezeNet | 40 |
| 3.4.9. Çapraz Doğrulama ve Performans Kriterleri | 41 |
| 4. ARAŞTIRMA BULGULARI VE TARTIŞMA..... | 50 |
| 4.1. AlexNet Sınıflandırma Sonuçları..... | 50 |
| 4.2. ResNet-50 Sınıflandırma Sonuçları | 55 |
| 4.3. GoogleNet Sınıflandırma Sonuçları..... | 60 |
| 4.4. InceptionV3 sınıflandırma sonuçları..... | 65 |
| 4.5. ShuffleNet sınıflandırma sonuçları | 70 |
| 4.6. SqueezeNet sınıflandırma sonuçları..... | 76 |
| 5. SONUÇLAR VE ÖNERİLER | 82 |
| 5.1. Sonuçlar | 82 |
| 5.2. Öneriler | 86 |
| 6. KAYNAKLAR | 88 |



SİMGELER VE KISALTMALAR

Simgeler

| | |
|--------|------------------------|
| p | : Olasılık |
| \sum | : Toplam |
| x_i | : Nöron giriş değeri |
| w_i | : Nöron ağırlık değeri |

Kısaltmalar

| | |
|--------|--|
| ACR | : Amerikan radyoloji koleji |
| ADC | : Apparent diffusion coefficient |
| ANN | : Artificial neural network |
| BT | : Bilgisayarlı tomografi |
| CAD | : Bilgisayar destekli tespit |
| CBF | : Cerebral blood flow |
| CBV | : Cerebral blood volume |
| CNN | : Convolutional neural network |
| CPU | : Central processing unit |
| CTA-SI | : Bilgisayarlı tomografi anjiyografi görüntüleri |
| CUDA | : Compute unified device architecture |
| DAG | : Difüzyon ağırlıklı görüntü |
| DCA | : Karar eğrisi analizi |
| DESA | : Derin evrışimsel sinir ağı |
| DICOM | : Tıpta dijital görüntüleme ve iletişim |
| dk | : Dakika |
| DSC | : Dice similarity coefficient |
| DSN | : Algılama ve segmentasyon ağı |
| ESA | : Evrışimli sinir ağı |
| FCN | : Fully convolutional network |
| FOM | : Liyakat rakamı |
| Gb | : Gigabayt |
| GEMSH | : General medical sistem hispeed |
| GPU | : Graphics processing unit |
| HMCAS | : Hiperdens orta serebral arter sinyali |
| HU | : Hounsfield unit |
| ICH | : İntra serebral kanama |
| ISLES | : İskemik inme lezyon segmentasyonu mücadelesi |
| kNN | : k-nearest neighbors |
| MAP | : Maksimum posteriori olasılık |
| MCA | : Orta serebral arter |
| MFLOPS | : Mega floating-point operations per second |
| MLP | : Multilayer perceptron |
| mm | : Milimetre |
| MPFN | : Çok düzlemlili füzyon ağı |
| MR | : Manyetik rezonans |
| MRG | : Manyetik rezonans görüntüleme |

| | |
|---------|---|
| MRI | : Magnetic resonance imaging |
| MTT | : Mean transit time |
| NCCT | : Kontrastsız bilgisayarlı tomografi |
| NEMA | : Ulusal elektrik üreticileri birliđi |
| NIHSS | : National institutes of health stroke scale |
| PNG | : Portable network graphics |
| PSO | : Parçacık sürü optimizasyonu |
| RAM | : Random access memory |
| RBF | : Radyal temel fonksiyon |
| ReLU | : Rectified linear unit |
| Res-FCN | : Residual-structured fully convolutional network |
| ROC-AUC | : Receiver operating characteristics area under curve |
| RSNA | : Kuzey Amerika Radyoloji Derneđi |
| SISS | : Sub-akut inme lezyon segmentasyonu |
| SPES | : Akut inme penumbra tahmini |
| SVH | : Serebrovasküler hastalıklar |
| SVM | : Support vector machine |

ŞEKİLLER LİSTESİ

| | |
|---|----|
| Şekil 2.1. Beyin kanaması veri seti görüntüleri | 3 |
| Şekil 2.2. Görüntü ön işleme | 4 |
| Şekil 2.3. Sistem tarafından kafatası ve beyin dokularının ayrılmış hali | 6 |
| Şekil 2.4. DICOM formatında görüntülerden 32 x 32 boyutunda parça görüntü eldesi .. | 7 |
| Şekil 3.1. İskemik inme | 20 |
| Şekil 3.2. Akut iskemik inme SMIR.Brain.XX.O.CT.345562 – 7. kesit BT görüntüsü | 21 |
| Şekil 3.3. Hemorajik inme ID_18cdd767f isimli BT görüntüsü | 22 |
| Şekil 3.4. Bilgisayarlı tomografi cihazı | 22 |
| Şekil 3.5. Helikal (spiral) BT çalışma yöntemi | 23 |
| Şekil 3.6. Hounsfield skalasında gri tonların dağılımı | 24 |
| Şekil 3.7. ISLES 2018 ana sayfası | 25 |
| Şekil 3.8. ISLES 2018 örnek görüntüleri | 25 |
| Şekil 3.9. RSNA Intracranial Hemorrhage Detection ana sayfası..... | 26 |
| Şekil 3.10. RSNA 2019 örnek görüntüleri | 26 |
| Şekil 3.11. Nöron yapısı | 28 |
| Şekil 3.12. Yapay sinir hücresi yapısı | 30 |
| Şekil 3.13. Çok katmanlı yapay sinir ağ yapısı | 32 |
| Şekil 3.14. LeNet ağ yapısı | 33 |
| Şekil 3.15. 5x5x3 boyutta bir giriş görüntüsüne 3x3'lük filtrenin uygulandığı konvolüsyon işlemi | 33 |
| Şekil 3.16. ReLU katmanının çıkış verisine etkisi. | 34 |
| Şekil 3.17. 4x4'lük giriş görüntüsüne, 2x2 filtre ile iki adım kaymalı maksimum havuzlama işlemi. | 35 |
| Şekil 3.18. ESA yapısı | 35 |
| Şekil 3.19. Düzleştirme katman, tam bağlantılı katman örneği..... | 36 |
| Şekil 3.20. AlexNet ağ yapısı | 37 |
| Şekil 3.21. ResNet ağ yapısı | 38 |
| Şekil 3.22. GoogleNet ağ yapısı | 39 |
| Şekil 3.23. Inception-V3 konvolüsyon ağ yapısı | 39 |
| Şekil 3.24. Grup evrişimi..... | 40 |
| Şekil 3.25. SqueezeNet ağ yapısı | 41 |
| Şekil 3.26. AlexNet 1. Döngü ROC grafiği..... | 48 |
| Şekil 3.27. AlexNet 1. Döngü karmaşıklık matrisi..... | 48 |
| Şekil 4.1. AlexNet beş döngünün % doğruluk grafiği..... | 51 |
| Şekil 4.2. AlexNet beş döngünün kayıp oranı grafiği | 51 |
| Şekil 4.3. AlexNet 1. Döngü karmaşıklık matrisi ve ROC grafiği..... | 52 |
| Şekil 4.4. AlexNet 2. Döngü karmaşıklık matrisi ve ROC grafiği..... | 53 |
| Şekil 4.5. AlexNet 3. Döngü karmaşıklık matrisi ve ROC grafiği..... | 53 |
| Şekil 4.6. AlexNet 4. Döngü karmaşıklık matrisi ve ROC grafiği..... | 54 |
| Şekil 4.7. AlexNet 5. Döngü karmaşıklık matrisi ve ROC grafiği..... | 54 |
| Şekil 4.8. ResNet-50 beş döngünün % doğruluk grafiği | 56 |
| Şekil 4.9. ResNet-50 beş döngünün kayıp oranı grafiği..... | 57 |
| Şekil 4.10. ResNet-50 1. Döngü karmaşıklık matrisi ve ROC grafiği | 57 |
| Şekil 4.11. ResNet-50 2. Döngü karmaşıklık matrisi ve ROC grafiği | 58 |
| Şekil 4.12. ResNet-50 3. Döngü karmaşıklık matrisi ve ROC grafiği | 58 |
| Şekil 4.13. ResNet-50 4. Döngü karmaşıklık matrisi ve ROC grafiği | 59 |
| Şekil 4.14. ResNet-50 5. Döngü karmaşıklık matrisi ve ROC grafiği | 59 |
| Şekil 4.15. GoogLeNet beş döngünün % doğruluk grafiği | 61 |

| | |
|---|----|
| Şekil 4.16. GoogLeNet beş döngünün kayıp oranı grafiği | 62 |
| Şekil 4.17. GoogLeNet 1. Döngü karmaşıklık matrisi ve ROC grafiği..... | 62 |
| Şekil 4.18. GoogLeNet 2. Döngü karmaşıklık matrisi ve ROC grafiği..... | 63 |
| Şekil 4.19. GoogLeNet 3. Döngü karmaşıklık matrisi ve ROC grafiği..... | 63 |
| Şekil 4.20. GoogLeNet 4. Döngü karmaşıklık matrisi ve ROC grafiği..... | 64 |
| Şekil 4.21. GoogLeNet 5. Döngü karmaşıklık matrisi ve ROC grafiği..... | 64 |
| Şekil 4.22. InceptionV3 beş döngünün % doğruluk grafiği | 66 |
| Şekil 4.23. InceptionV3 beş döngünün kayıp oranı grafiği | 67 |
| Şekil 4.24. InceptionV3 1. Döngü karmaşıklık matrisi ve ROC grafiği | 67 |
| Şekil 4.25. InceptionV3 2. Döngü karmaşıklık matrisi ve ROC grafiği | 68 |
| Şekil 4.26. InceptionV3 3. Döngü karmaşıklık matrisi ve ROC grafiği | 68 |
| Şekil 4.27. InceptionV3 4. Döngü karmaşıklık matrisi ve ROC grafiği | 69 |
| Şekil 4.28. InceptionV3 5. Döngü karmaşıklık matrisi ve ROC grafiği | 70 |
| Şekil 4.29. ShuffleNet beş döngünün % doğruluk grafiği..... | 71 |
| Şekil 4.30. ShuffleNet beş döngünün kayıp oranı grafiği | 72 |
| Şekil 4.31. ShuffleNet 1. Döngü karmaşıklık matrisi ve ROC grafiği..... | 72 |
| Şekil 4.32. ShuffleNet 2. Döngü karmaşıklık matrisi ve ROC grafiği..... | 73 |
| Şekil 4.33. ShuffleNet 3. Döngü karmaşıklık matrisi ve ROC grafiği..... | 74 |
| Şekil 4.34. ShuffleNet 4. Döngü karmaşıklık matrisi ve ROC grafiği..... | 74 |
| Şekil 4.35. ShuffleNet 5. Döngü karmaşıklık matrisi ve ROC grafiği..... | 75 |
| Şekil 4.36. SqueezeNet beş döngünün % doğruluk grafiği | 77 |
| Şekil 4.37. SqueezeNet beş döngünün kayıp oranı grafiği..... | 77 |
| Şekil 4.38. SqueezeNet 1. Döngü karmaşıklık matrisi ve ROC grafiği | 78 |
| Şekil 4.39. SqueezeNet 2. Döngü karmaşıklık matrisi ve ROC grafiği | 78 |
| Şekil 4.40. SqueezeNet 3. Döngü karmaşıklık matrisi ve ROC grafiği | 79 |
| Şekil 4.41. SqueezeNet 4. Döngü karmaşıklık matrisi ve ROC grafiği | 80 |
| Şekil 4.42. SqueezeNet 5. Döngü karmaşıklık matrisi ve ROC grafiği | 80 |

ÇİZELGE LİSTESİ

| | |
|---|----|
| Çizelge 3.1. Beş kat çapraz geçerleme tablosu..... | 42 |
| Çizelge 3.2. Karmaşıklık matrisi | 42 |
| Çizelge 3.3. Örnek ağ eğitim özellikleri tablosu | 48 |
| Çizelge 4.1. AlexNet ağ eğitim özellikleri | 50 |
| Çizelge 4.2. AlexNet performans değerleri | 50 |
| Çizelge 4.3. AlexNet ROC-AUC değerleri ve beş döngü ortalaması | 55 |
| Çizelge 4.4. ResNet-50 ağ eğitim özellikleri..... | 55 |
| Çizelge 4.5. ResNet-50 ağ performans değerleri..... | 55 |
| Çizelge 4.6. ResNet-50 ROC-AUC değerleri ve beş döngü ortalaması..... | 60 |
| Çizelge 4.7. GoogLeNet ağ eğitim özellikleri..... | 60 |
| Çizelge 4.8. GoogLeNet ağ performans değerleri..... | 61 |
| Çizelge 4.9. GoogleNet ROC-AUC değerleri ve beş döngü ortalaması | 65 |
| Çizelge 4.10. InceptionV3 ağ eğitim özellikleri..... | 65 |
| Çizelge 4.11. InceptionV3 ağ performans değerleri..... | 66 |
| Çizelge 4.12. Inception V3 ROC-AUC değerleri ve beş döngü ortalaması..... | 70 |
| Çizelge 4.13. ShuffleNet ağ eğitim özellikleri | 71 |
| Çizelge 4.14. ShuffleNet ağ performans değerleri | 71 |
| Çizelge 4.15. ShuffleNet ROC-AUC değerleri ve beş döngü ortalaması | 75 |
| Çizelge 4.16. SqueezeNet ağ eğitim özellikleri..... | 76 |
| Çizelge 4.17. SqueezeNet ağ performans değerleri..... | 76 |
| Çizelge 4.18. SqueezeNet ROC-AUC değerleri ve beş döngü ortalaması..... | 81 |
| Çizelge 5.1. Tüm ağların performans değerleri..... | 82 |
| Çizelge 5.2. Tüm ağların ROC – AUC performans değerleri | 82 |
| Çizelge 5.3. Makalelerin ve tez çalışmasının karşılaştırma çizelgesi..... | 83 |

1. GİRİŞ

Dünyada sakat kalmanın 1. nedeni, ölümlerin ise 3. nedeni olan inme bir beyin damar hastalığıdır. Serebrovasküler hastalıklar (SVH), hastanede tedavi gerektiren nörolojik hastalıkların %50'sinden fazlasını oluşturur. İnmenin %85'i iskemik, %15'i ise hemorajiktir (kanama). Ülkemizde, SVH'nin %72'sini iskemik inme %28'ini ise hemorajik inmenin oluşturduğu saptanmıştır (Şahan ve ark., 2010). Hastalık beyinde olduğu bölgeye göre vücudun farklı kısımlarında felç oluşturmaktadır. Bu da iş gücü kaybı ve bakım maliyetini beraberinde getirmektedir. İnme durumunda hastaya hızlı müdahale kişinin beklenen yaşam süresinin uzamasını ve engellilik durumunun azalmasını sağlamaktadır. Dolayısıyla hastalık beyinde görüldüğü anda hızlı bir teşhis konulması ve inme olan bölgenin hızlı bir şekilde belirlenmesi hastanın hayat kalitesini önemli oranda arttıracaktır (Emre, 2013).


Hastalığa teşhis konulmasında, bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) teknikleri önemli bir yer tutmaktadır. İnme hastalığının tespitinde BT görüntüleri ve manyetik rezonans (MR) görüntüleri uzman bir radyolog doktor tarafından yorumlanır. Tetkik raporuna göre hemoraji ise kanama protokolü başlatılır. İnmenin sebebi iskemi ise trombolitik protokolü başlatılır. Fakat iskemik inmelerde bulguların başlamasından itibaren ilk 3 saatlik süre aşılmamış olmalıdır . Yeni bulgular bu sürenin 4.5 saate kadar uzatılabileceğini göstermektedir (Emre, 2013). Nörolojide zaman beyindir. Zaman ne kadar çok harcanırsa, risk altındaki beyin dokuları da o oranda kaybedilmektedir.

Medikal görüntü analizleri hastanelerde uzman radyologlar tarafından yapılmaktadır. Görüntü analizinde zaman kısıtlaması, uzmana ulaşmada problemler, küçük hastane ve bölgelerde radyolog eksikliği, deneyime göre değişen yorumlamalar gibi bir takım problemler oluşabilmektedir. Hastanelerde çok fazla görüntü alınması, birçok hastalığa ait görüntü analizi yapılması gerekliliği, ancak buna karşın radyolog sayısının az olması da medikal görüntü analiz süreçlerini yavaşlatmaktadır. Son dönemlerde medikal görüntü analizlerinin görüntü işleme ve yapay zekâ yöntemleri ile gerçekleştirme hedefinde olan çalışmaların sayısı artmaktadır (Karthik ve ark., 2020). Görüntülerin ön işlemlerden geçirilerek yüksek hızlı bilgisayarlarda analizlerinin yapılması ve görüntüdeki hastalık hakkında doktora bir ön bilgi gelmesi gelecekte tıp alanında beklenen bir teknolojidir (Dourado Jr ve ark., 2019).

Acile gelen hastada inme sebebinin iskemi veya kanama olup olmadığı ön görülememektedir. Bu tez çalışmasında iki farklı veri tabanından alınan BT görüntüleri kullanılarak yapay zekâ yöntemleri olan farklı derin öğrenme modelleri ile iki inme türünün sınıflandırılması yapılmıştır. İskemik İnme Lezyon Segmentasyon yarışması 2018 (ISLES 2018) ve Kuzey Amerika Radyoloji Derneği (RSNA) veri tabanlarından 300 adet iskemik beyin BT görüntüsü, 300 adet kanama beyin BT görüntüsü, 300 adet normal beyin BT görüntüsü kullanılmıştır. Görüntüler %80 eğitim %20 test verisi olarak işleme alınmış, 5 kat çapraz geçerleme ile doğrulama yapılmıştır. AlexNet, ResNet, GoogleNet, InceptionV3, ShuffleNet, Squeeze modelleri ile inme görüntüleri ayrılmış ve sınıflandırılmıştır. Hassasiyet, duyarlılık, F1 puanı, doğruluk ve süre kriterleri ile ağların başarı performansları karşılaştırılmıştır. Tez çalışması sonucunda modellerin hastalık sınıflandırma performansları karşılaştırılmış, sistemlerin avantaj ve dezavantajları tartışılmıştır.

2. KAYNAK ARAŞTIRMASI

Phong ve ark. (2017), yapmış oldukları çalışmada, yeni mezun radyologlara yardımcı olması amacı ile vakaları sınıflandırmada derin öğrenme modellerinden faydalanmıştır. Veri kümesi olarak Vietnam'daki 115 hastaneden 100 beyin kanaması vakasının BT görüntüleri oluşturulmuştur. Şekil 2.1.'de çalışmada kullanılan BT görüntülerinden bir kısmı gösterilmektedir. Kanama alanları, kırmızı elipsle işaretlenmiştir.




Şekil 2.1. Beyin kanaması veri seti görüntüleri (Phong ve ark., 2017)

XL250a GEN9, 2 x E5-2680 v3, 128 GB RAM, ve 2 x Intel Xeon Phi 7120P yardımcı işlemcili bilgisayarda LeNet, GoogLeNet ve Inception-ResNet derin öğrenme ağ yapıları kullanılarak beyin kanaması tespiti yapılmıştır. Görüntü sayısını artırmak, veriyi zenginleştirmek ve analizi kısıtlayacak alanların kaldırılması için veri setindeki görüntüler ön işleme tabi tutulmuştur. Bu işlemlerde hasta ismi, çekim bilgileri gibi görüntüdeki metinler kaldırılmıştır. Görüntüler 90° , 180° ve 270° döndürülmüştür.


Inception-ResNet ağ yapısının bu çalışma için en iyi ağ yapısı olduğu belirtilmiştir (Phong ve ark., 2017).

Dourado Jr ve ark. (2019), yapmış oldukları çalışmada çevrimiçi derin öğrenme ile inme tespiti yapmışlardır. Çalışmada *General Medical Sistem HiSpeed TC* sistemi (GEMSH) ile veri tabanlarından elde edilen görüntüler, Amerikan Radyoloji Koleji (ACR) ve Ulusal Elektrik Üreticileri Birliği (NEMA) tarafından oluşturulan dijital tıbbi görüntüleme standardı olan Tıpta Dijital Görüntüleme ve İletişim (DICOM) formatı kullanılarak kayıt edilmiştir. Bu çalışmada; DICOM görüntülerini okumak için OFFIS tarafından sağlanan DCMTK açık kaynak kitaplığı (DICOM Araç Takımı) kullanılmıştır. Aksiyal düzlemde görüş alanı 230 mm, dilim kalınlığı 0.7 mm, 512×512 piksel ve $0.585 \times 0.585 \times 1.5$ mm voksel büyüklüğü, 16 bit derinliği, 40 HU bandı - 80 HU özelliklerinde olan görüntüler bir uzman tarafından incelenerek altın standart (*ground truth*) alanları belirlenmiştir. 140 normal beyin, 140 iskemik inme, 140 hemorajik inmeli beyin görüntüsü çalışmada kullanılmıştır. Bayes sınıflandırmada Gauss olasılık yoğunluk fonksiyonu kullanılmıştır. *k-nearest neighbors*'da (kNN), k hiperparametresi 1-11 aralığındaki tek değerler parametre olarak belirlenmiştir. *Multilayer Perceptron* (MLP) eğitimi, gizli katmandaki nöron sayısı 2 ile 1000 arasında değişen *Levenberg-Marquardt* yöntemi kullanılarak gerçekleştirilmiştir. *Support Vector Machine* (SVM), 2^{-5} , 2^{-4} , 2^{-3} , aralığının değerlerine göre değişen C ve γ hiperparametreleri ile doğrusal ve radyal temel fonksiyon (RBF) çekirdeklerini dikkate almıştır. Java ile Keras ve TensorFlow kütüphanelerinin kullanıldığı python dilinde yazılmış bütünleşik program kullanılmıştır. Yazılım ve donanım özellikleri: Intel Xeon sunucu, 16 çekirdekli işlemci, 32 GB RAM, linux ubuntu 16.04 64-bit işletim sistemi, python versiyonu 3 ve java versiyonu 1.8.0'dir. Data seti %80 eğitim, %20 test verisi olarak işleme alınmıştır. Ön işlem olarak, veriler normalleştirilmiştir. Her bir ağ yapısında bayes, MLP, k-NN, random forest, SVM (lineer), SVM (rbf) sınıflandırıcılar kullanılmıştır. DICOM görüntülerde, Mobile-Net, doğruluk ve duyarlılık %91.57, F1 puanı %91.40 ve kesinlik %91.76 değerleriyle en yüksek sonucu vermiştir. Gri skala görüntülerde Nas-Net, bayes hariç tüm sınıflandırıcılarda doğruluk, duyarlılık, F1 puanı ve kesinlik %100'dür. En hızlı eğitim süreleri bayesian sınıflandırıcıya sahip VGG16 ve VGG19 olup, her ikisi de 0.015 s sürmüştür. Ardından DenseNet121 ve Nas-Net mobile sırasıyla 0.019 s ve 0.020 s ile gelmektedir. Bu çalışmanın, doğruluk oranları ve algoritma sonuçlanma süreleri ile bilgisayar destekli teşhise yardımcı olması açısından başarılı bir uygulama olduğu belirtilmiştir (Dourado Jr ve ark., 2019).

Chin ve ark. (2017), otomatik iskemik inmenin derin öğrenme ile tespitinin yapılması amacıyla yaptıkları çalışmada, ilk olarak görüntüler ön işleme tabi tutulmuştur. Beyin omurilik sıvısı ve kafatası alanları otsu yöntemi ile görüntüden çıkarılmıştır (Şekil 2.3.). 5 mm kalınlığında, 512x512 piksel boyutundaki DICOM görüntü 32x32 piksel boyutlarında parçalara ayrılıp (Şekil 2.4.) veri çoğaltma ile görüntü sayısı 256 adete yükseltilmiştir. Veri çoğaltmada aynı görüntünün bir piksel sağa, sola, yukarı veya aşağı kaydırılması ile oluşturulmuştur. Bu görüntülerin %50'si eğitim, %50'si test verisi olarak alınmış ve Evrişimli sinir ağı (ESA) yapısında kullanılmıştır. ESA yapısı bir adet maksimum havuzlama katmanı, iki adet konvolüsyon katmanı, bir adet tam bağlantı katmanı ve bir adet softmax katmanından oluşmaktadır. İşlemler; 3 GHz CPU, 16GB RAM, Nvidia GTX 960 GPU donanımı üzerine kurulu Ubuntu 16.04. işletim sisteminde yapılmıştır. Yazılım C ve Lua Script dilini kullanmaktadır. Makine öğrenmesinde Torch kullanılmıştır. Şekil 2.3.'te verilerde yapılan ön işleme, Şekil 2.4.'te veri çoğaltma gösterilmektedir.



Şekil 2.3. Sistem tarafından kafatası ve beyin dokularının ayrılmış hali (Chin ve ark., 2017)



Şekil 2.4. DICOM formatında görüntülerden 32 x 32 boyutunda parça görüntü eldesi (Chin ve ark., 2017)

Çalışma sonucunda hastalığın sınıflandırılmasında %92.96 doğruluk değerine ulaşılmıştır. Elde edilen sonucun, teşhis konulması aşamasında fayda sağlayacağı belirtilmiştir (Chin ve ark., 2017).

Liu ve ark. (2018), MR görüntüsü üzerinde inme lezyon görüntüsünün segmente ettikleri çalışmada, difüzyon ağırlıklı görüntüleri (DAG), *Apparent diffusion coefficient* (ADC) görüntüleri, T2 ağırlıklı görüntüleri *residual-structured fully convolutional network* (Res-FCN) ağında işleme almışlardır. Görüntüdeki her bir pikselin inme olasılığı eşik değerinin üstünde olduğu durumda piksele 1 değeri, değilse 0 değeri verilerek yeni bir segmente alanı elde edilmiştir. Bu sonuç *ground truth* ile karşılaştırılmış ve ağ eğitilmiştir. Tüm görüntülere normalizasyon işlemi uygulanmıştır. Çalışmada temel ağ olarak ResNet50 kullanılmaktadır. 115 eğitim dosyası, 97 test dosyası modele giriş olarak verilmiştir. İşlemde donanım olarak, alienware aurora r6 iş istasyonu, intel core i7-7700k CPU, 48Gb RAM, NVIDIA GeForce 1080ti GPU, 11 GB hafıza ile çalışılmıştır. İşletim sisteminde linux (ubuntu 14.4), CUDA 8.0, Keras ve Tensorflow kütüphaneleri kullanılmıştır. ~18 dk. süren işlem, süre açısından performansı yükseltmiştir. Segmentasyon performans kriterlerinden 0.654 dice değeri ile başarılı sonuç alındığını belirtmektedirler (Liu ve ark., 2018).

Chen ve ark. (2017) ESA ile Difüzyon Ağırlıklı MR görüntülerinde tam otomatik inme lezyon segmentasyonu yaptıkları çalışmada, 741 vaka görüntüsünün evrişimli sinir

ağında (EDDNet) işleme tabi tutmuşlardır. Elde edilen sonuçları konvolüsyonel etiket değerlendirme ağı MUSCLE Net ile işleme alınmıştır. İşlemlerde doğru sınıflanmış vaka sayısının tüm vakalara oranı ile lezyon tespit oranı hesaplanmaktadır. Çalışmanın sonucunda lezyon tespit oranı 0.94 sonucu elde edilmiştir. Küçük lezyonlarda ve büyük lezyonlarda dice değerleri sırasıyla 0.61 ve 0.83'tür. Ortalama dice değeri 0.67'dir. Ağların ilk eğitimi toplamda 26.72 saat sürmüştür. Test süresi ise toplamda 0.9 saniyedir. Süre ve dice değeri olarak performansı yüksek sonuç elde edildiği belirtilmiştir (Chen ve ark., 2017).

Rajini ve Bhavani (2013) iskemik inmenin bilgisayar destekli tespitini yaptıkları çalışmada, BT görüntülerinde iskemik inme bölgesini sağlıklı dokulardan ayıran segmentasyon, orta hat kayması ve görüntü özelliklerini kullanarak iskemik inmenin otomatik olarak saptanmasına yönelik yeni bir yaklaşım sunmaktadır. Önerilen yöntem, ön işleme, segmentasyon, beynin orta hattının izlenmesi, doku özelliklerinin çıkarılması ve sınıflandırma olmak üzere beş aşamadan oluşmaktadır. İskemik inmenin erken tespiti için önerilen yöntemin uygulanmasının, klinik uygulamanın etkinliğini ve doğruluğunu arttırdığı gösterilmiştir. Sonuçlar, bir uzman tarafından nicel olarak değerlendirilmiştir. Önerilen yaklaşım ile elde edilen sonuçlar arasındaki ortalama örtüşme metriği, ortalama hassasiyet ve ortalama duyarlılık sırasıyla 0.98, 0.99 ve 0.98'dir. SVM, k-NN, *artificial neural network* (ANN) ve karar ağacı ile %98, %97, %96 ve %92 doğrulukta sınıflandırma sonucuna ulaşılmıştır (Rajini ve Bhavani, 2013).

Pereira ve ark. (2018), hemorajik ve iskemik inmeyi aynı anda tespit eden bir çalışma yapmışlardır. Parçacık Sürü Optimizasyonu (PSO) ile optimize edilmiş ESA kullanılarak BT görüntülerinde inme tespiti yapılmıştır. Veri seti, her vaka için üç farklı görüntüden oluşturulmuştur. Veri seti içeriğini orijinal BT görüntüsü, segmentli kafatası görüntüsü ve radyolojik yoğunluk harita görüntüsü oluşturmaktadır. Tomografi görüntüleri dilim kalınlığı 0.7 mm, görüş alanı 230 mm, piksel boyutları 512 x 512, Voxel boyutları 0.585 x 0.585 x 1.5 mm'dir. *Clinical Trajano Almeida - Diagnostic Imaging* desteğiyle 25 BT vakası incelenmiştir. BT taramaları DICOM formatında olup içeriği; 100 normal beyin, 100 hemorajik inme, 100 iskemik inme görüntüsünden oluşmaktadır. BT görüntüleri, X ışınının vücuttan geçemediği noktalarda daha az yoğunlukta geçerler. Bu zayıflama değeri Hounsfield birimleri (HU) ile ölçülen zayıflama katsayısı olarak adlandırılan yerel doku yoğunluğu ile orantılıdır. Düşük yoğunluklu dokular daha koyu pikseller halindedir. Yüksek yoğunluklu dokular pozitif değerler alır ve daha açık gri tonlamalı piksel halinde temsil edilir. Ön işlemede görüntüler yeniden 256 x 256 piksel

olarak boyutlandırılmıştır. Veri seti; %50 eğitim, %50 test görüntüsü olan birinci protokol ve %75 eğitim, %25 test görüntüsü olan ikinci protokol olarak ayrı ayrı işlemlere tabi tutulmuştur. Parçacık Sürü Optimizasyon metodolojisi, eğitim seti üzerinden ESA kayıp fonksiyonunu en aza indirecek şekilde en iyi hiper parametre değerlerini seçmektedir. Optimale yakın hiper parametreler kullanılarak ağ eğitilmektedir. Bu çalışma için düzenlenmiş ESA ile 75/25 protokolünde; Hemorajik inmeyi %97.5 oranında, iskemik inmeyi %100 oranında, normal beyin görüntüsünü %99.1 oranında doğru tespit ederek, yüksek performans değerlerine ulaştıkları bildirilmiştir (Pereira ve ark., 2018).

Clèrigues ve ark. (2020) multimodal MR görüntülerinden akut ve subakut inme lezyonu segmentasyonu yaptıkları çalışmada, akut ve subakut inme lezyonu segmentasyonu için U-Net tabanlı bir derin öğrenme metodolojisi önermektedir. Beyin yarım kürelerinin simetrisine dayalı öğrenmede performansı artırmak için veriler, ön işleme tabi tutulmuştur. Sınıf dengesizliği sorunu, dengeli bir eğitim örnekleme stratejisi ve dinamik ağırlık kayıp işlevi ile küçük boyutlu görüntüler kullanarak ele alınmıştır. Önerilen yöntem, ISLES 2015 veri setinde kullanılmıştır. Yarışma, çoklu difüzyon, perfüzyon ve anatomik MRG modalitelerinden sub-akut inme lezyon segmentasyonu (SISS) ve akut inme penumbra tahmini (SPES) görevlerini içermektedir. SISS *Dice similarity coefficient* – Dice benzerlik katsayısı (DSC) $DSC=0.59 \pm 0.31$ ve SPES alt görevleri için $DSC=0.84 \pm 0.10$ değerleri ile yüksek performans elde etmiştir. Sunulan diğer stratejilerle karşılaştırıldığında, daha düşük bir Hausdorff mesafesi ile en üst düzeyde performans elde edildiği bildirilmiştir (Clèrigues ve ark., 2020).

Majumdar ve ark. (2018) BT görüntülerinden intrakraniyal hafif kanamaları tespit etmeye yardımcı olacak bilgisayar destekli sistem çalışması yapmışlardır. Çalışmada hizalama, görüntü işleme, görüntüleri düzeltme, elle özellik çıkarma ve sınıflandırma adımlarını içeren klasik bir yaklaşım yerine aynı anda özellikleri ve sınıflandırmayı öğrenen derin bir evrimsel sinir ağı kullanılmıştır. Birden fazla elle müdahale adımını ortadan kaldırmış ve özgüllüğü önemli ölçüde artıracak ESA çıktısına son işlem uygulanmıştır. Veri seti; eğitim, doğrulama ve test için sırasıyla 60, 5 ve 69 vakaya bölünmüş 134 BT vakasından (4.300 görüntü) oluşturulmuştur. Her vaka tipik olarak birden fazla kanama içermektedir. Test setindeki performans, lezyon başına %81 duyarlılık (34/42 lezyon) ve vaka başına %98 özgüllük (45/46 vaka) göstermektedir (Majumdar ve ark., 2018).

Gautam ve Ramanın (2021) beyin BT görüntülerini hemorajik inme, iskemik inme ve normal beyin olarak sınıflandırdıkları çalışma, üç grubun aynı anda sınıflandırıldığı

önemli bir çalışmadır. Yeni önerilen evrişimli sinir ağı modeli, görüntü füzyonu ve ESA yaklaşımlarını kullanmaktadır. Tüm işlemler, Himalayan Tıp Bilimleri Enstitüsünden elde edilen BT görüntü veri seti üzerinde yapılmıştır. İlk olarak, BT görüntülerinin kalitesini iyileştirmek için çok odaklı görüntü füzyonu kullanılarak ön işleme uygulanmıştır. Ön işlenmiş görüntüler, inme sınıflandırması için yeni önerilen 13 katmanlı ESA mimarisinde işleme alınmıştır. ESA yönteminin doğruluğu, iki farklı veri seti üzerinde iki deney yapılarak kontrol edilmiştir. Birinci deneyde, BT görüntü verileri, %20 test ve %80 eğitim setlerine bölünmüştür, ikinci deneyde görüntü veri setine on kat çapraz geçiş yapılmıştır. Veri kümesi 1'de birinci deneyde elde edilen sınıflandırma doğruluğu %98.33 ve ikinci deneyde %98.77 iken, veri kümesi 2'de deney 1 ve 2'de elde edilen doğruluk değerlerinin sırasıyla %92.22 ve %93.33 olduğu bildirilmiştir (Gautam ve Raman, 2021).

Pan ve ark. (2021) kontrastsız BT görüntülerinde iskemik enfarktüsü tespit etmek amacıyla yaptıkları çalışmada, akut iskemik inme teşhisinin doğruluğunu artırmak için temel olarak derin öğrenme rezidual ağına (ResNet) dayalı yeni bir yaklaşım ele almışlardır. Bu çalışmada normal bireylerin manyetik rezonans difüzyon ağırlıklı görüntüleri ile doğrulanmış iskemik inme hastalarının (başlangıç süresi: 9 saatten az) görüntüleri kullanılmıştır. Hepsine aynı tarama aralığı, katman kalınlığı (4 mm) ve katmanlar arası mesafe (4 mm) ile BT düz tarama ve MR-DAG taraması yapılmıştır. (İki inceleme arasındaki zaman aralığı: 4 saatten azdır). MR-DAG'yi enfarktüs çekirdeğinin altın standardı olarak belirlemek ve kontrastsız BT görüntülerinde enfarktüs çekirdeğini tespit etmek için bir maksimum posteriori olasılık (MAP) modeli ve bir son işleme yöntemiyle birlikte derin öğrenme modeli olan ResNet kullanılmıştır. Bu yeni yöntemin klinik değerini analiz etmek için karar eğrisi analizi (DCA) kullanılmıştır. 116 iskemik inmeli hasta ve 26 normal kişinin olduğu veri seti kullanılmıştır. 58 hasta görüntüsü eğitim veri setine, 58 hasta ile 26 normal kişi görüntüleri test veri setine ayrılmıştır. Kontrastsız BT'de enfarktüs çekirdeğini tespit etmek için ResNet tabanlı tanımlama doğruluğu %75.9 olarak elde edilmiştir. Bu derin öğrenme yönteminin, iskemik inme hastalarının teşhisinde fayda sağlayacağı düşünülmüştür. Optimizasyon yöntemleriyle desteklenen derin öğrenme rezidual ağı, kontrastsız BT görüntülerinde erken enfarktüs çekirdeğini saptayabileceği ve hekimlerin akut iskemik inme hastalarında tanı doğruluğunu artıracığı sonucuna ulaşılmıştır (Pan ve ark., 2021).

Lo ve ark. (2021) çalışmalarında kontrastsız bilgisayarlı tomografik görüntülerini kullanan derin konvolüsyonel sinir ağları ile akut iskemik inmenin otomatik tanımlandığı

bir yaklaşım önermektedir. Görüntü veri seti, akut iskemik inme 96 hastadan (573 görüntü) ve 121 normal kontrolden (681 görüntü) alınan 1254 gri tonlamalı kontrastsız BT görüntüsünden oluşmaktadır. İki nöroradyolog kritik inme bulgularının bir altın standardını oluşturmuştur. ESA olarak AlexNet, Inception-v3 ve ResNet-101 kullanılmıştır. Sınırlı veri boyutunu eğitmek için ImageNet parametreleriyle transfer öğrenme uygulanmıştır. Oluşturulan modeller, on kat çapraz geçişle değerlendirilmiş ve başka bir kurumdan akut iskemik inme 50 hasta (108 görüntü) ve 58 normal kontrol (117 görüntü) içeren bağımsız bir veri kümesi üzerinde test edilmiştir. Önceden eğitilmiş parametreler olmadan AlexNet, %97.12'lik doğruluk, %98.11'lik hassasiyet, %96.08'lik özgüllük ve 0.9927 *Receiver operating characteristics area under curve* (ROC-AUC) değeri elde etmiştir. Transfer öğrenme kullanılan AlexNet, Inception-v3 ve ResNet-101 %90.49 ile %95.49 arasında doğruluk elde etmiştir. Başka bir kurumdan alınan veri seti ile test edilen AlexNet, %60.89 doğruluk, %18.52 duyarlılık ve %100 özgüllük sonuçları vermiştir. Transfer öğrenme kullanılan AlexNet, Inception-v3, ResNet-101 sırasıyla %81.77, %85.78 ve %80.89 doğruluk elde etmiştir. Bilgisayar destekli bir teşhis sistemi olarak önerilen derin ESA mimarisi, sıfırdan eğitimin belirli bir tarayıcı için özelleştirilmiş bir model oluşturabileceğini ve transfer öğreniminin radyologlara akut iskemik inmenin tanısını önerilerde bulunacak daha genelleştirilmiş bir model oluşturabileceğini gösterdiği bildirilmiştir (Lo ve ark., 2021).

Watanabe ve ark. (2021) BT görüntülerinde kafa içi kanamayı tespit için derin öğrenme tabanlı bilgisayar destekli tespitin (CAD) farklı seviyedeki doktorların teşhis performansı üzerindeki etkisini aydınlatmak amacıyla çalışma yapmışlardır. Toplam 40 kafa BT veri seti (normal, 16; hemorajik, 24), 15 doktor (5 kurul onaylı radyolog, 5 radyoloji asistanı ve 5 tıp stajyeri) tarafından değerlendirilmiştir. Hekimler CAD'siz ve CAD'li 2 okuma seansına katılmıştır. Tüm doktorlar, vakaları incelemişlerdir. Her vakada okuma süresi kaydedilmiştir. CAD sistemi, 433 hastanın kafa BT görüntüleri (normal, 203; hemorajik, 230) kullanılarak geliştirilmiştir. Kanama oranları, U-Net ve makine öğrenimine dayalı yanlış pozitif çıkarma yöntemi kullanılarak karşılık gelen olasılık ısı haritaları olarak gösterilmektedir. Duyarlılık, özgüllük, doğruluk ve liyakat rakamı (FOM), açıklamalara ve güven seviyelerine göre hesaplanmıştır. Algoritma beyin kanamasını tespit etmek için U-Net kullanılarak geliştirilmiştir. U-Net'i eğitmek için toplam 433 kafa BT taraması kullanılmıştır. 5 mm kesit kalınlığına sahip kafa BT taramaları; 203 beyin normal (5326 dilim) ve kanamalı 230 hasta (2588 dilim) görüntülerinden oluşmaktadır. İki hasta grubundan elde edilen veriler rastgele, eğitim

(%90) ve doğrulama (%10) veri setlerine ayrılmıştır. CAD sistemi, sırasıyla her dilimdeki her piksel ve her hasta için bir ICH (İntra serebral kanama) tahmin verileri elde etmiştir. Bu sonuçlar şu işlemlerle elde edilmiştir: ön işleme, derin öğrenme tabanlı segmentasyon ve yanlış pozitif alanları görüntüden çıkarma. Ön işlemede gürültü ve işleme tabii tutulmayacak alanlar görüntüden çıkarılmıştır. Çeşitli pencere seviyesi ve genişlik ayarları kullanılarak farklı parlaklıkta görüntüler elde edilmiştir. Ön işlemeden sonra, çoklu görüntüler için bağımsız olarak eğitilmiş ve oluşturulmuş U-Net'ler kullanılarak her dilimdeki ICH bölgeleri tespit edilmiştir. Bu algılama oranları birleştirilerek her dilim için ICH değeri belirlenmiştir. Kalsifikasyon bölgeleri ve kan damarları gibi yanlış pozitif sonuçlu görüntüleri ortadan kaldırmak için, dilim düzeyinde ICH'lerin olasılık ısı haritalarına, makine öğrenimine dayalı bir yanlış pozitif alanları görüntüden çıkarma yöntemi uygulanmıştır. Spesifik olarak, bir olasılık eşiğini aşan pikseller aday bölgeler olarak çıkarılmıştır. Her bölgenin BT değerlerinden uzamsal konumları hesaplanmıştır. Bu özelliklere dayanarak bir bölgenin yanlış pozitif olup olmadığı random forest yöntemiyle belirlenmektedir. Bölgenin yanlış pozitif olup olmadığı, karşılık gelen olasılıklar hesaplanmıştır. Makine öğrenmesi tabanlı yanlış pozitif alanları görüntüden çıkarma yöntemi uygulanarak hasta düzeyinde intraserebral kanama yerleri belirlenerek hasta düzeyinde intraserebral kanama olasılık değeri tahmin edilmiştir. Gerçekleştirilen CAD sisteminde, dilim düzeyindeki ve hasta düzeyindeki sonuçlar ile olasılık haritaları oluşturulmuştur. Olasılık ısı haritaları her hastanın beyin BT görüntüsüne işlenmiştir. Sonuçta CAD kullandıktan sonra hasta bazlı değerlendirmede, tüm doktorların ortalama doğruluğu önemli ölçüde %83.7'den %89.7'ye ($p < 0.001$) yükselmiştir. Ek olarak, kurul onaylı radyologların, radyoloji asistanlarının ve stajyer hekimlerin doğrulukları CAD olmadan sırasıyla %92.5, 82.5 ve %76.0 ve CAD ile sırasıyla %97.5, %90.5 ve %81'dir. CAD kullandıktan sonra tüm doktorların ortalama FOM'u 0.78'den 0.82'ye ($p = 0.004$) yükselmiştir. CAD (43 s) kullanıldığında okuma süresi, tüm doktorlar için kullanılmadığı zamana göre (68 s, $p < 0.001$) anlamlı olarak daha düşüktür. Sonuç olarak derin öğrenme kullanılarak geliştirilen CAD sisteminin, tüm doktorlar için kafa içi kanamayı tespit etmede tanı performansını önemli ölçüde iyileştireceği öne sürülmüştür (Watanabe ve ark., 2021).

Gia ve ark. (2020) intrakraniyal kanamanın BT görüntülerinden bilgisayar destekli tespit ettikleri (CAD) bir çalışma yapmışlardır. MobileNetV2 mimarisine dayalı derin öğrenme modeli, RSNA kafa içi kanama veri seti üzerinde eğitilmiştir. Vietnam'daki Vinh Long Eyalet Hastanesi'nden toplanan ICH Vietnam vakaları ile veri

seti oluşturulmuştur. Sonuçta 0.991 ROC-AUC, 0.992 duyarlılık ve 0.807 özgüllük değerleri elde edilmiştir (Gia ve ark., 2020).

Hong ve ark. (2019), serebral mikro kanamaları ESA transfer öğrenme metodu ile tespit ettikleri bir çalışma yapmıştır. Serebral mikrokanamalar, normal (veya normale yakın) dokuda serebral küçük damarlardan sızan küçük perivasküler hemosiderin birikintileridir. Son on yılda, Serebral mikro kanamaları yarı otomatik ve otomatik olarak tespit etmek için geleneksel makine öğrenimi ve klasik evrişimli sinir ağlarına dayalı birkaç yaklaşım geliştirilmiştir. Son yıllarda, görüntü tanıma için, klasik ESA ile karşılaştırıldığında daha iyi performans gösteren, daha derin yapıya sahip çok sayıda gelişmiş ESA varyantı önerilmektedir. Bu çalışmada Serebral mikro kanama tespitinin doğruluğunu daha da geliştirme olasılığını araştırmak için ResNet-50'ye dayalı bir yöntem önerilmiştir. Örneklem büyüklüğü nedeniyle transfer öğrenme kullanılmıştır. ResNet-50'nin transfer öğrenmesine dayanarak, ortalama \pm standart sapma formatında $\%95.71 \pm 1.044$ hassasiyet, $\%99.21 \pm \%0.076$ özgüllük ve $\%97.46 \pm 0.524$ doğruluk ile yüksek performans elde edildiği bildirilmiştir (Hong ve ark., 2019).

Dawud ve ark. (2019) beyin kanamasını, özellikle kanamanın erken evrelerinde tespit etme problemini ele alan bir çalışma yapmıştır. AlexNet ve ayrıca destek vektör makinesi sınıflandırıcılı AlexNet'in (AlexNet-SVM) değiştirilmiş yeni bir sürümü kullanılmıştır. ESA, BT görüntülerini kanamalı veya kanamasız görüntü olarak sınıflandırmaktadır. Bu çalışmada amaç önceden eğitilmiş bir modelin (transfer öğrenme) sıfırdan bir ESA oluşturma ihtiyacını ortadan kaldırıp kaldıramayacağı konusu araştırılmasıdır. Buna ek olarak, üç katmanlı bir sinir ağı yerine sınıflandırıcı olarak SVM kullanmanın avantajlarını araştırmayı amaçlamaktadır. Aynı sınıflandırma görevi üç derin ağa uygulanmıştır. Birinci ağ baştan tasarlanmıştır. İkinci ağ beyin BT kanama sınıflandırma işlemine göre düzenleme yapılmış önceden eğitilmiş ağıdır. Üçüncü ağ, SVM sınıflandırıcısını kullanan modifiye yeni AlexNet-SVM modelidir. Üç ağ, aynı sayıda mevcut beyin BT görüntüsü kullanılarak eğitilmiştir. Deneyler, doğal görüntülerden tıbbi görüntü sınıflandırmasına bilgi aktarımının mümkün olduğunu göstermektedir. Elde edilen sonuçların önerilen modifiye edilmiş önceden eğitilmiş model "AlexNet-SVM"nin beyin kanamasını tanımlamada sıfırdan oluşturulan evrişimli bir sinir ağından ve orijinal AlexNet'ten daha iyi performans gösterebileceğini öne sürmektedirler (Dawud ve ark., 2019).

Jung ve Whangbo (2020) derin öğrenme ile iskemik inme tespit ettikleri çalışmalarında, küçük bir veri setiyle iskemik inme için öğrenme ve sınıflandırma

yapabilen bir derin öğrenme sistemi önermektedirler. Bu çalışmada orta serebral arter (MCA) bölgesinden 356 inmeli hastanın kontrastsız BT görüntüleri verilerine dayanan iskemik inme için optimize edilmiş bir ön işleme algoritması geliştirilmiştir. Sinir ağlarını eğitirken yetersiz veri sorununun üstesinden gelmek için transfer öğrenme modülünü optimize eden, uyarlamalı transfer öğrenme algoritması kullanılmıştır. Hali hazırda kullanılan SEResNext sinir ağı ile önerilen sistem karşılaştırıldığında, inme teşhisi performansı mevcut SEResNext sinir ağı sistemine göre %18.72 daha iyi sonuç verdiği bildirilmiştir (Jung ve Whangbo, 2020).

Karthik ve ark. (2020), derin öğrenme modellerinin inme tespiti ve lezyon segmentasyonundaki etkisini değerlendirmek amacıyla bir derleme yapmıştır. Bu derlemede son birkaç yılda farklı akademik araştırma veri tabanlarında yayınlanan 113 araştırma makalesi analiz edilmiştir. İnme lezyonu tespiti ve segmentasyonundaki gelişmelere odaklanılmıştır. Araştırma makaleleri, inme lezyonu tespiti ve segmentasyonu ile ilgili en belirgin iç görüleri elde etmek için belirli kriterlere göre filtrelenmiştir. İnme lezyonunun özellikleri görüntüleme yöntemine göre değişmektedir. Etkili bir yöntem geliştirmek için, girdi görüntülerinden özniteliklerin dikkatlice çıkarılması gerekmektedir. Çalışmada inme lezyonu tespiti ve segmentasyonu için kullanılan farklı derin mimariler kategorize edilmiş ve karşılaştırılmıştır. Çalışma tıbbi görüntü analizindeki iki derin sinir ağı bileşenlerinin, yani Evrişimli Sinir Ağı ve Tam Evrişimli Ağ - *Fully convolutional network* (FCN) alaka düzeyinin anlaşılmasına yardımcı olmaktadır. Daha iyi sonuçlar için önerilebilecek diğer olası derin mimarilere işaret edilmiştir. Ayrıca, inme tespitinde ortaya çıkan eğilimler ve çalışmalar bu değerlendirmede detaylandırılmıştır.

Bu çalışma ile araştırmacıların karşılaştığı teknik ve teknik olmayan zorlukları inceleyerek ve inme tespitinde gelecekteki etkileri gösterilmiştir. Derin öğrenme, tıbbi alanda önemli sonuçlar vermiş olsa da, karmaşık görüntü segmentasyonu problemlerini çözmek için derin mimarileri kullanma konusunda dikkate değer araştırma beklentileri bulunmaktadır. Tıp doktorlarının bu araştırmalara girmesiyle daha iyi sonuçlar elde edileceği düşünülmektedir. Şu anda, derin öğrenmeye dayalı segmentasyon algoritmaları, veri yetersizliği, eğitim süresi ve kaynaklar vb. gibi faktörlerle sınırlıdır. Bu sınırlamaların üstesinden gelmek için verimli yöntemler tasarlandığı takdirde, biyomedikal görüntü işleme alanında derin öğrenmenin daha iyi sonuçlar vereceği öngörülmüştür (Karthik ve ark., 2020).

Yu ve ark. (2020) akut iskemik inmeli hastalarda temel görüntüleme derin öğrenme modeli kullanılarak nihai enfarktüs lezyonlarının tahmin edilebilirliğinin araştırıldığı bir çalışma yapmıştır. Akut iskemik inme geçiren 182 hastanın prognoz bulguları çalışmasında, akut ve takip görüntülerinden oluşan bir veri seti ile eğitilmiş derin öğrenme modeli başlangıçtan 3 ila 7 gün sonra kullanılmıştır. Çalışma yapılırken sonraki reperfüzyon durumu hakkında bilgi sahibi olmadan enfarktüs lezyonlarının boyutunu ve yerini tahmin etmek amaçlanmıştır. Model, küçük ve büyük reperfüzyonlu hastalarda mevcut klinik son teknoloji yöntemlerle karşılaştırılabilir performans göstermiştir. Derin öğrenme modeli müdahaleden önce akut iskemik inme geçiren hastalar için bireyselleştirilmiş enfarktüs lezyon tahmini sağlamaktadır. Akut inme geçiren hastalarda enfarktüs boyutunun ve yerinin tahmini, karar verme ve prognoz için önemlidir. Çalışma ile derin öğrenme modelinin manyetik rezonans görüntülerini kullanarak nihai enfarktüs lezyonlarını tahmin edip edemeyeceği ve modeli güncel klinik tahmin yöntemleri ile karşılaştırıp karşılaştıramayacağı araştırılmıştır. Bu çok merkezli prognostik çalışmada, görüntü segmentasyonu (U-net) için bir sinir ağı türü eğitilmiş ve sonuçlar doğrulanmıştır. İşlem, perfüzyon ağırlıklı ve difüzyon ağırlıklı MR görüntülerine 3 ila 7 gün sonra uygulanmaktadır. Hastalar 24 saatlik görüntüleme sonuçlarına göre bilinmeyen, minimal, kısmi ve majör reperfüzyon olarak gruplanmaktadır. 182 vakada (97 kadın [%53.3]; ortalama 65 yaş), derin öğrenme modeli ortalama ROC-AUC 0.92 değeri elde etmiştir. Derin öğrenme modeli ile mevcut klinik yöntemler karşılaştırılmış olup derin öğrenme modelinin daha iyi olduğu öne sürülmüştür. ESA'nın reperfüzyon bilgisi olmadan temel görüntüleme enfarktüs lezyonlarını başarıyla tahmin ettiği ve mevcut klinik yöntemlerle karşılaştırılabilir performans elde ettiği bildirilmiştir. Subakut enfarktüs lezyonunun tahmin etmede, klinisyenlerin dekompresyon tedavisine hazırlanmasında yardımcı olabileceği önerilmiştir (Yu ve ark., 2020).

Zhang ve ark. (2020) yapmış oldukları iskemik inmeyi segmente edecek çok düzlemli füzyon ağı çalışmasında, manuel segmentasyonunun zaman alan ve öznel olmasından kaynaklı sorunların önüne geçmek istemektedir. Başlangıçtan trombüsün çıkarılmasına kadar geçen süre, akut iskemik inmeli hastaların prognozu üzerinde önemli bir etkiye sahiptir. Süre ne kadar kısa olursa, prognoz o kadar iyi olur. Bu amaçla, DAG'da iskemik inme lezyonlarını hızlı ve otomatik olarak segmente edilmesi için yeni bir çalışma sunulmuştur. İlk olarak, iki tür veri dengesizliğini çözmek için algılama ve segmentasyon ağı (DSN) tasarlanmıştır. İkinci olarak, sırasıyla farklı düzlem özelliklerini

çıkarmak için kullanılan üç dallı bir DSN mimarisi önerilmiştir. Üçüncü olarak, nihai tahmini daha doğru yapmayı amaçlayan çok düzlemlili bir füzyon ağı (MPFN) önerilmiştir. ISLES2015 SISS DAG dizi veri seti üzerinde kapsamlı deneyler yapılmış, önerilen segmentasyon yöntemi ile dice değerinin %62.2'ye ve duyarlılık değerinin %71.7'ye ulaştığı bildirilmiştir (Zhang ve ark., 2020).

Zhang, Zhao, ve ark. (2018) 3 boyutlu evrişimli sinir ağları kullanarak difüzyon ağırlıklı görüntülerden akut iskemik inmeyi bölümlere ayırmak için yeni bir otomatik yöntem önerilen bir çalışma yapmıştır. Metot, ayırt edici özellikleri otomatik olarak öğrenebilmekte ve 3 boyutlu bağlamsal bilgileri, verimli bir şekilde kullanabilmektedir. Çok derin 3-D ESA eğitiminin zorluğunu azaltmak için, ağ boyunca engelsiz bilgi ve yayılımını sağlamak için ağ, yoğun bağlantı ile donatılmıştır. Yöntemi değerlendirmek için çeşitli akut iskemik inme tiplerine sahip 242 vaka (eğitim için 90, doğrulama için 62 ve test için 90) içeren bir DAG veri seti oluşturulmuştur. Modelin, çeşitli metriklerde (Dice benzerlik katsayısı: %79.13, lezyona göre kesinlik: %92.67 ve lezyona göre F1 puanı: %89.25) yüksek performans elde ederek diğer en son teknoloji ESA yöntemlerini büyük bir farkla geride bıraktığı belirtilmiştir. Modeli ISLES2015-SISS veri seti üzerinde de değerlendirip, genelleme kapasitesini daha da ortaya koyan oldukça rekabetçi bir performans elde ettiği öne sürülmüştür. Önerilen yöntemin hızlı oluşu ve doğruluğu, teşhislerde faydalı olacağı belirtilmiştir (Zhang, Zhao, ve ark., 2018).

Perez Malla ve ark. (2019) MR perfüzyon görüntülerinin ESA ile segmentasyonunun değerlendirildiği bir çalışma yapmıştır. Bu çalışmada yaygın olarak kullanılan MR perfüzyon görüntülerinin, serebral iskemiye değerlendirmek için en son teknolojiye sahip yöntemlerden biri olan konvolüsyonel sinir ağları ile tespiti amaçlanmıştır. Otomatik desen tanımda ve dolayısıyla segmentasyon görevlerinde başarılı olan ESA, bu çalışmada iskemik inme segmentasyonunda başarılı olamamıştır. Bugüne kadar geliştirilen ESA mimarilerinin hiçbiri iskemik inme lezyonlarını segmente etmede yüksek doğruluk elde edemediği öne sürülmüştür. Başarı oranının düşük olmasında görüntüleme modalitesinde konum, şekil, boyut, görüntü yoğunluğu ve dokudaki heterojenliklerin sebep olduğu bildirilmiştir. İşlemlerde bir uzmanın raporlandığı, 43 inme hastasının difüzyon ağırlıklı perfüzyon ve difüzyon beyin MR görüntülerini içeren ISLES 2017 veri seti kullanılmıştır. İnme lezyonlarının segmentasyonunda gelişmiş makine öğrenimi tekniklerinin veri büyütme, transfer öğrenimi ve son işlemin etkisini değerlendirmek için ESA kullanılmıştır. Değerlendirilen tüm teknikler arasında, ikili kapanış ile veri büyütme işleminin en iyi

sonuçları verdiği öne sürülmüştür. Ortalama dice puanının, temel modele göre % 17 daha yüksek olduğu öne sürülmüştür. Önceki çalışmalarla uyumlu olarak, büyük lezyonların varlığında daha iyi performans elde edildiği bildirilmiştir (Perez Malla ve ark., 2019).

Öman ve ark. (2019) üç boyutlu konvolüsyonel sinir ağları kullanılarak bilgisayarlı tomografi anjiyografi görüntülerinden (CTA-SI) iskemik inme tespitinin fizibilitesini araştırmak amacıyla bir çalışma yapmıştır. Yöntemler orta serebral arterde akut iskemik inme şüphesi olan rastgele seçilmiş 60 hastanın CTA-SI'sı kullanılmıştır. Sinir ağı eğitiminde 30 hasta görüntüsü kullanılmış ve daha sonra kalan 30 hasta görüntüsü test edilmiştir. Eğitim ve test görüntüleri manuel olarak segmente edilmiştir. Serebral hemisferik karşılaştırma için CTA ve kontrastsız bilgisayarlı tomografi (NCCT) görüntüleri ile kullanılmıştır. Klinik olarak inme tanısı alan hastalarda ilgili bölgeler, 0.93 duyarlılık ve 0.82 özgüllük ile enfarktüs olarak etiketlenmiştir. Çalışma voxel açısından ROC-AUC değeri 0.93, en yüksek dice benzerlik katsayısı ise 0.61 olarak elde edilmiştir. Giriş özelliği olarak serebral hemisferik karşılaştırma kullanıldığında algoritma performansı arttığı bildirilmiştir. Kontrastsız görüntülerin etkisinin az olduğu belirtilmiştir. Akut iskemik inme lezyonun CTA-SI verilerinden 3D konvolüsyonel sinir ağı tabanlı yazılımla tespit edilebileceği öne sürülmüştür. Beynin diğer yarımküresinden elde edilen bilgilerin kullanılması, yanlış pozitif bulgu sayılarının azaltılmasında faydalı olacağı belirtilmiştir (Öman ve ark., 2019).

Shinohara ve ark. (2020) akut iskemik inmeli hastalarda kontrastsız BT hiperdens orta serebral arter (MCA) sinyalinin (HMCAS) etkileşimli, derin öğrenme destekli bir tanımlamasını geliştirmek amacıyla bir çalışma yapmıştır. İlgili alanlardan çıkarılan 50 piksel çaplı dairesel 35 HMCAS pozitif ve 39 HMCAS negatif örnek, deneyimli iki nöroradyoloğun ortak kararına göre onaylanmıştır. Görüntüler, eğitim ve doğrulama veri setleri olarak ayrılmıştır. Eğitim örneklerinin sayısını artırmak için veri büyütme işlemi yapılmıştır. Giriş görüntülerini HMCAS-pozitif veya -negatif olarak sınıflandırmak için derin bir evrişimsel sinir ağı (DESA - Xception) kullanılmıştır. HMCAS'ı tanımlamaya yönelik derin öğrenmeye dayalı eğitim modelinin hassasiyetini, özgüllüğünü ve doğruluğunu tahmin etmek için bir vaka dışarıda bırakma çapraz doğrulaması uygulanmıştır. Sonuçlar tanılama performansı açısından HMCAS için DESA'dan, bir vaka dışarıda bırakılan çapraz doğrulamada %82.9 duyarlılık, %89.7 özgüllük ve %86.5 doğruluk, ROC –AUC 0.947 sonuçları elde edilmiştir (%95 güven aralığı 0.895-0.998; P<0.05). Sonuç olarak derin öğrenme yöntemi ile akut iskemik inmeli hastalarda

kontrastsız BT'de HMCAS'ı belirlemek için faydalı olacağı ileri sürülmüştür (Shinohara ve ark., 2020).

Soltanpour ve ark. (2019) BT perfüzyon görüntülerinden piksel düzeyinde sınıflandırıcı, çoklu paralel u-net kullanılarak iskemik inme lezyonunun tespit edildiği bir çalışma yapmıştır. Çalışmada manuel segmentasyonun zor ve zaman alıcı bir süreç olduğu zamanın önemi açısından iskemik inme lezyon segmentasyonu için uygun olmayacağı ileri sürülmüştür. Literatürde önerilen birkaç otomatik iskemik inme lezyonu segmentasyonu analiz yönteminin manuel özellikleri kullandığı, düzensiz ve fizyolojik şekillerden dolayı, iskemik inme lezyonlarının önceden tanımlanmış basit özellikler kullanılarak otomatik bir şekilde doğru tahmin edilemeyeceği öne sürülmüştür. Bu çalışmada, iskemik inme lezyonunun segmentasyonu için model öğrenen otomatik bir tahmin algoritması önerilmiştir. Model, dört BT perfüzyon haritasından (*Cerebral blood volume* - CBV, *Cerebral blood flow* - CBF, *Mean transit time* - MTT, Tmax) inme lezyonunun konumu hakkında gerekli bilgileri çıkarmak için dört adet 2D U-Net kullanmaktadır. Model daha sonra piksellerin lezyon mu yoksa sağlıklı doku mu olduğuna karar vermek için U-Net tarafından çıkarılan olasılık haritalarını birleştirmektedir. Bu yaklaşım, inme lezyonunu öğrenmek için her pikselin, komşularının bilgilerini de kullandığı işlemlerden oluşur. Segmentasyon performansı, dice benzerlik katsayısı, hacim benzerliği ve duyarlılık parametreleri kullanılarak değerlendirilmiştir. Bu yeni algoritma ISLES 2018 yarışma veri setinde kullanılmıştır. Bu çalışmanın en gelişmiş yaklaşımlardan daha iyi sonuçlar elde ettiği öne sürülmüştür (Soltanpour ve ark., 2019).

3. MATERYAL VE YÖNTEM

3.1. İnme

İnme beyin dokularının pıhtı, damar daralması, damar kapanması, kanama sebebiyle beslenemeyerek canlılığını yitirmesi ile beyin hücrelerinin yönettiği vücudun ilgili alanlardaki kontrolünü kaybetmesidir. Yaş, cinsiyet, ırk, genetik faktörler, ailede inme ya da geçici iskemik atak öyküsü, hipertansiyon, sigara kullanımı, şeker hastalıkları, kalp hastalıkları, kan hastalıkları, obezite, beslenme alışkanlıkları, hareketsizlik, postmenapozal hormon tedavisi gibi faktörler inme oluşumunu etkilemektedir.

Ülkemizde ve dünyada iskemik inme oranı hemorajik inmeye göre daha fazladır. (Şahan ve ark., 2010).

İnme hastalığı oluşumunda hiper tansiyon, sigara kullanımı ve yaşlılık daha etkilidir (Çolak ve ark., 2020). Beyin hücreleri, dokularının beslenememesi ile fonksiyon kaybına uğramaktadır. İnme sonucunda, beyin hücreleri vücudun ilgili olduğu alanı yönetmemektedir. İnmenin olduğu bölge, hayati fonksiyonların yönetildiği merkez olduğundan; etkilenmenin olduğu oranda hastanın hayati tehlikesi artmaktadır.

İnme belirtileri vücudun bir tarafında ani uyuşma veya güçsüzlük, denge kaybı, ani görme bozuklukları, yutmada güçlük, baş dönmesi, yürüme de problem yaşama, ani gelişen dikkati toparlayamama, konuşma veya anlamada zorluk, yüz kaslarında simetri bozukluğu, bilinç kaybıdır.

İnme tedavisinde zaman çok önemlidir. Oksijen eksikliğinde, beyin hücreleri birkaç dakika içinde ölmeye başlar. Beyin hasarını engelleyebilecek pıhtılaşmayı önleyen ilaçlar vardır, ancak inme semptomlarının görülmesinden itibaren birkaç saat içinde – 4,5 saate kadar – kullanılmaları gerekir.

Teşhis konulmasında, bilgisayarlı tomografi ve manyetik rezonans görüntüleme tetkikleri ileri derecede öneme sahiptir. İnme hastalığının tespitinde BT görüntüleri ve MR görüntüleri uzman bir radyolog doktor tarafından yorumlanmaktadır. BT çekim süresi 3-5 dk. olup, oldukça kısadır. Daha az kontrendikasyonu olmaktadır. Fakat hasta radyasyon almaktadır. Hamilelerde kullanımı sakınca oluşturabilmektedir. MR çekimlerinde birkaç sekans birlikte çekilmektedir. Bu da çekim süresini uzatmaktadır. Ayrıca MR cihazı manyetik alan oluşturduğu için, kalp pili gibi hasta vücudunda bulunan metal protezleri etkilemektedir. Bu hastalar da MR çekilememektedir. Bu sebeple BT çekimi daha ön plandadır. İnme geçiren hastaya 4,5 saat içerisinde müdahale edilerek,


kalıcı sakatlık veya ölüm riski en aza indirilmelidir. (Emre, 2013). Hasta hızlı bir şekilde hastaneye ulaştırılmalı, teşhis konularak tedavisine başlanmalıdır (Şahan ve ark., 2010).

İnme yaklaşımında ilk olarak fiziksel muayene yapılmaktadır. Muayene sonucunda *National Institutes of Health Stroke Scale* (NIHSS) puanı ve Glasgow skoru hesaplanmaktadır. Bilgisayarlı Tomografi ve gerekirse Difüzyon MR çekilmektedir. Süre önemli olduğu için genelde bu işlemler teşhis için yeterlidir. Tetkik sonuçlarına göre tedaviye başlanmaktadır. İskemik atakta pıhtı için trombolitik tedavi ve/veya trombektomi uygulanır. Hemorajik inme için anti ödem tedavisi uygulanır (Emre, 2013).

Oluş sebebine göre inme iskemik inme ve hemorajik inme olarak ikiye ayrılır.

3.1.1. İskemik inme


İskemik inme en yaygın görülen inme türüdür. Kolesterol, yağ, kalsiyum ve vb. diğer maddeler belli bir süre sonra atardamarlarda birikmeye başlar. Bu faktörler damarlarda tıkanma ve daralmaya neden olur. Dokular, beslenemeyip infarkt alanı oluşturmakta ve nekroz dokusuna dönüşmektedir. Doku, vücuttaki hangi alanı yönetiyorsa o bölgede fonksiyon kaybı meydana gelmektedir (Emre, 2013). Şekil 3.1.'de pıhtı, kapanma ve daralma sebebiyle damar tıkanması gösterilmektedir.



Şekil 3.1.İskemik inme (Acharya ve ark., 2019)

İnme şüphesi ile gelen kişi de ilk tanı, inmenin hangi tipte olduğunun belirlenmesidir. İnmenin türüne göre tedavi yaklaşımları değişmektedir. Zaman önemli

olduğu için hızlı bir şekilde BT taraması yapılarak inme semptomlarının hangi türe ait olduğu belirlenmektedir. Oluşan pıhtının etkilediği alan lokalize edilebilmektedir. İskemik inme kararı verilirse hızlı bir şekilde pıhtılaşmayı önleyen ilaçlar ile müdahale edilmektedir. Akut iskemik inme BT görüntüsü Şekil 3.2.'de verilmiştir. Görüntüler uzman radyolog ve nörolog tarafından değerlendirilmektedir. İskemi, kanama alanı görüntüsü gibi çok net biçimde görülmemektedir. Beyaz - gri madde ayrımında kayıp, ödem sebebiyle yarım küre simetrisinin bozulması, tıkalı arterin belirginliği gibi faktörler konunun uzmanı doktorlar tarafından incelenmekte ve iskemi kararı verilmektedir.



Şekil 3.2. Akut iskemik inme SMIR.Brain.XX.O.CT.345562 – 7. kesit BT görüntüsü (Hakim ve ark., 2018)

3.1.2. Hemorajik inme

Hemorajik inme damar yırtılması ve damarın kan sızdırması durumunda meydana gelmektedir. Kanın damar dışına, dokuların içine; travma, lezyon, yüksek tansiyon vb. sebeplerden akması (kanama) sonucu beyin hücre yapısının bozulmaktadır. İlgili bölge fonksiyon kaybına uğramaktadır (Emre, 2013). İskemide olduğu gibi, beyin hücreleri vücudun ilgili olduğu alanı yönetememektedir. Dokunun önem derecesine göre hasta hayatı da bu derecede etkilenmektedir. BT görüntüsünde Şekil 3.3.'te verildiği üzere kanama alanı belirgin bir şekilde görülmektedir.



Şekil 3.3. Hemorajik inme ID_18cdd767f isimli BT görüntüsü (RSNA, 2019)


3.2. Bilgisayarlı Tomografi

Bilgisayarlı tomografi, X-ışını kullanılarak vücudu inceleyen medikal görüntüleme tekniğidir. Bir BT kesiti oluşturabilmek için, kesit düzlemindeki her noktanın x-ışını zayıflatma değerini bilmek gerekir. Bu değerler, kesit düzleminin çepeçevre her yönünden x-ışını geçirilerek yapılan çok sayıdaki ölçümün bilgisayarlarla işlenmesi ile bulunmaktadır. Bulunan bu sayısal değerler, karşılığı olan gri tonlarla boyanarak kesit görüntüleri elde edilmektedir (MEB, 2011). Şekil 3.4.'te BT cihazı verilmiştir.




Şekil 3.4. Bilgisayarlı tomografi cihazı (MEB, 2011)

BT çalışma prensibi / BT fiziği: Helikal (spiral) BT’de tüp inceleme sırasında sürekli dönmektedir, hasta masası ise bir yöne hareket etmektedir. Bir defada 40-80 cm’lik bir alan bir nefes tutma süresinde taranabilmektedir. Çok kesitli BT’de ise helikal teknolojiye ek olarak tek dedektör halkası yerine yan yana sıralanan dedektör halkaları kullanılmaktadır (Şekil 3.5.). Bu dedektör bloklarında halka sayısı 64’e kadar çıkmaktadır. Böylece aygıtın aynı anda taradığı hacim artmaktadır. X-ışını tüpü, kesit düzlemi çevresinde 360 derece dönerek dar bir X-ışını demeti gönderir. X-ışınları vücuda gönderilirken ölçülmekte, vücudu geçtikten sonra ölçülmekte, aradaki fark hesaplanarak dedektörlerin karşısına gelen dokunun X-ışınını ne oranda tuttuğu bulunmaktadır. Görüntü bu çok sayıdaki ölçümlerden karmaşık bilgisayar işlemleriyle oluşturulmaktadır (MEB, 2011).



Şekil 3.5. Helikal (spiral) BT çalışma yöntemi (MEB, 2011)

Dedektörlerin ölçtüğü ve dijitalize ettiği değerler, bilgisayarlar aracılığıyla her vokselin X-ışınlarını tutma değerlerine dönüştürülmektedir. Bu işlem suyun X-ışınını tutma değerini 0 kabul eden, bir ucu -1000 diğer ucu +1000 olan bir cetvele göre yapılmaktadır (Şekil 3.6.). Bu cetvele, yöntemi geliştirenlerden biri olan İngiliz fizikçisi Hounsfield’den dolayı Hounsfield Cetveli ve bu cetveldeki sayılara da BT Ünitesi veya Hounsfield Ünitesi (HÜ) adı verilmiştir (MEB, 2011).



Şekil 3.6. Hounsfield skalasında gri tonların dağılımı (MEB, 2011)

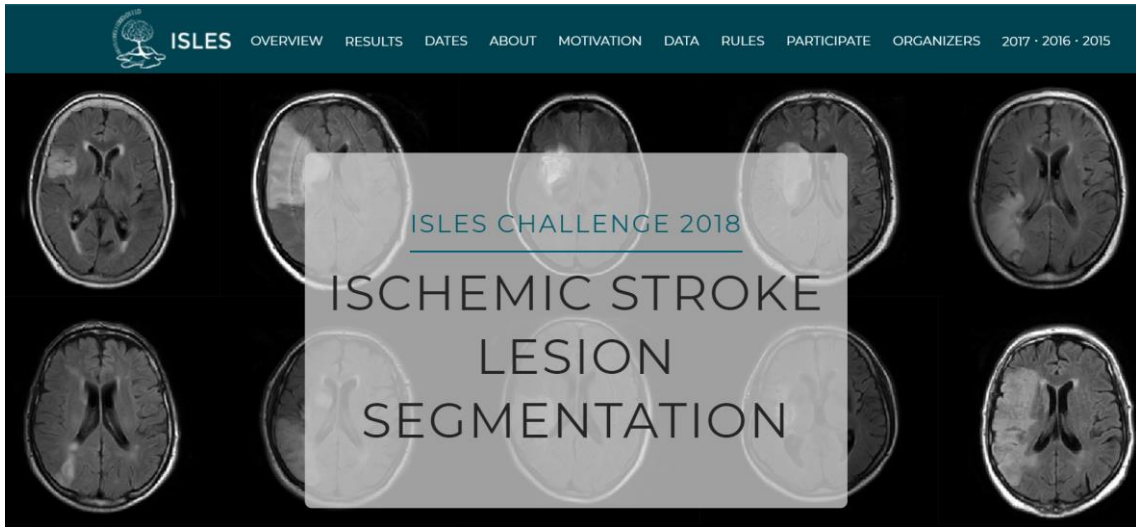
Güçlü Yanları: MR'a göre çekim süresi çok kısadır. Daha yaygın kullanımı vardır. Daha az kontrendikasyonu olmaktadır.

Zayıf Yanları: Hasta radyasyon almaktadır. MR'da olduğu gibi kontrast madde verilerek çekilen sekansı da vardır. Kontrast maddenin böbrekleri etkilemesi ve kullanılan kontrast maddenin 4 cm civarında kesit alanını görünür hale getirmesi zayıf taraflarıdır. (Dora ve ark., 2015)

3.3. Veri Tabanları


3.3.1. ISLES 2018

Tez çalışmasında iki olgunun da aynı anda incelenip sonuca daha hızlı ulaşılması amaçlanmıştır. İskemik inme verisi olarak, ISLES 2018 (Ischemic Stroke Lesion Segmentation) yarışmasında (Hakim ve ark., 2018) açık kaynak olarak kullanıma sunulan 300 adet NIfTI formatında iskemik beyin bilgisayarlı tomografi görüntüsü, 18 adet normal beyin tomografi görüntüsü kullanılmıştır. Şekil 3.7.'de ISLES 2018 ana sayfası verilmiştir (<http://www.isles-challenge.org>).



Şekil 3.7. ISLES 2018 ana sayfası (Hakim ve ark., 2018)

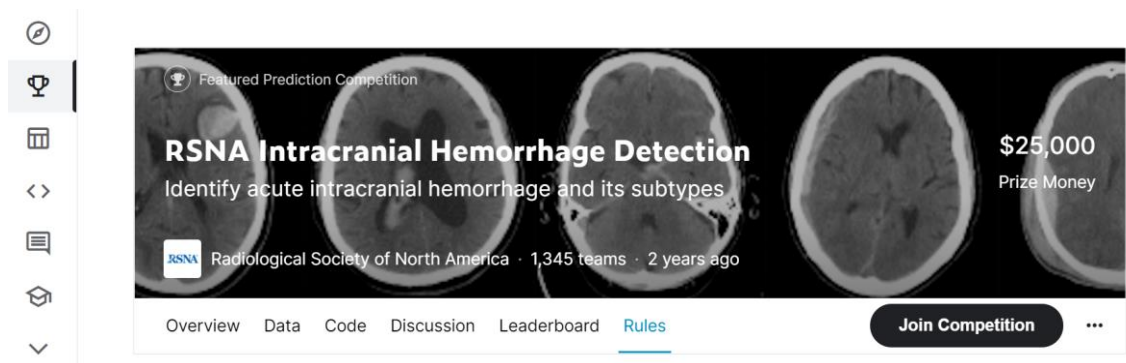
Her görüntünün adı, kesit numarası, sınıfına göre kesit adeti ve sınıfı Ek-1 de verilmiştir. ISLES 2018 açık kaynak görüntü adları, SMIR.Brain.XX.O.CT.***** şeklindedir. “ * ” simgeli alana altı haneli sayı gelmektedir. Nifti formatında olan ana görüntüler; kontrast değeri 120’ye, parlaklık değeri 60’a getirilip, PNG (*Portable Network Graphics*) resim formatında MRicro programı (Neuroimaging Informatics Tools and Resources Clearinghouse, 2020) ile kaydedilmiştir. İskemik inme içeren dilimler iskemi sınıfında, içermeyenler normal beyin görüntüsü klasöründe sınıflandırılmıştır. Şekil 3.8.’de iskemik ve normal beyin BT görüntüleri verilmiştir.



Şekil 3.8. ISLES 2018 örnek görüntüleri a) iskemik inme b) normal beyin BT görüntüsü (Hakim ve ark., 2018)


3.3.2. RSNA 2019

Kuzey Amerika Radyoloji Derneğinin 2019 yılında beyin kanaması yarışmasında (RSNA, 2019) açık kaynak olarak kullanıma sunduğu görüntülerden 300 adet beyin kanaması beyin bilgisayarlı tomografi görüntüsü ve 282 adet normal beyin bilgisayarlı tomografi görüntüsü kullanılmıştır. Şekil 3.9.'da RSNA ana sayfası verilmiştir (<https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/rules>).



Şekil 3.9. RSNA Intracranial Hemorrhage Detection ana sayfası

Her görüntünün adı, kesit numarası, sınıfına göre kesit adeti ve sınıfı Ek-1 de verilmiştir. DICOM formatında olan ana görüntüler; kontrast değeri 120'ye, parlaklık değeri 60'a getirilip, PNG resim formatında kaydedilmiştir (Şekil 3.10). RSNA kaynağından alınan görüntülerin adları, ID_***** şeklindedir. “ * ” simgeli alan, görüntü ismini ifade etmektedir. Kaynaktan, beyin kanaması görüntüsü olarak sınıflananlar ve normal beyin görüntüleri alınmıştır. Görüntüler kendi sınıflandırma klasörümüzde sınıflandırılmıştır.



Şekil 3.10. RSNA 2019 örnek görüntüleri a) kanama b) normal beyin BT görüntüsü (RSNA, 2019)

3.4. Derin Öğrenme

Derin öğrenme, “Yapay zekâ” ve “Makine öğrenmesi” alanlarındaki çalışmalardan sonra ortaya çıkmıştır. Yapay Zekâ, çeşitli uygulamaları insan gibi zeki faaliyetlerle yürütmesi amacıyla yapılmış bilgisayar veya bilgisayar sistemlerine verilen isimdir (Anonim, 2020). Yapay zekâ üzerine yapılan araştırmalar ilerledikçe bulunan sistemlerin makineye uygulanabilmesi için makine öğrenmesi önem kazanmıştır. Makine öğrenmesi temelde bilgisayar sistemlerinin yapay zekâ alanında sayısal öğrenme ve model tanıma uygulamalarından geliştirilmiş bir alt dalıdır. Makine öğrenme algoritmaları öğrenme ve girdiler üzerinden tahmin yapma üzerine kurulmuş bir yapıdır. Bu yapılar standart programlardan farklı olarak girilen bilgilerden tahmin ve karar verme, sonuç çıkartma amaçlı model oluşturularak çalışmaktadır. Makine öğrenme algoritmalarında temel; giriş verisi algoritması oluşturmak, çıktıları yeni girişler olduğunda güncellemek ve çıktıların tahmini için istatistiksel analiz kullanmaktır (İncir, 2020).

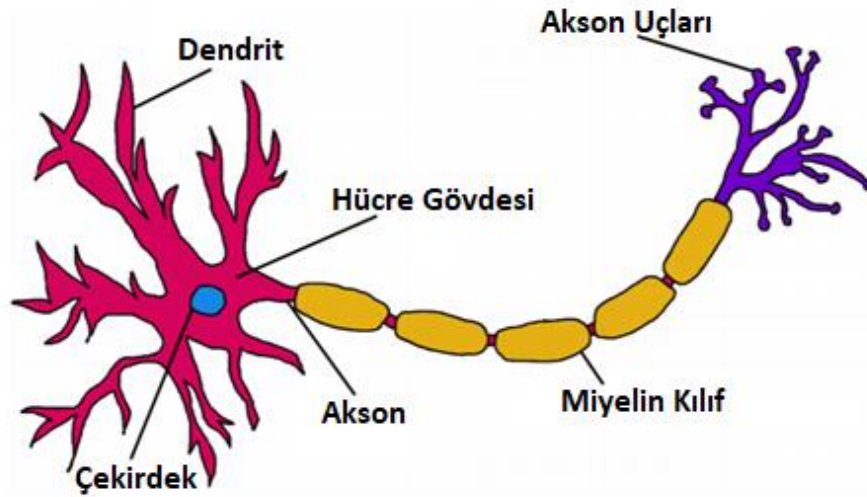
Derin öğrenme, insan beyninin problemleri çözmek için kullandığı yöntemlerden esinlenip büyük ölçekteki verilerden faydalanarak, özellik çıkarma, sınıflandırma ve karar verme gibi işlemleri yapan makine öğrenmesinin alt dalıdır. Yapay sinir ağı ara gelişmelerinden ortaya çıkan derin öğrenme kavramı “yeni nesil sinir ağları” olarak anılmaktadır. Yapısal olarak insan gibi düşünüp karar veren yapılar oluşturmayı amaçlamaktadır.

Günümüzde karmaşık yapılarda derin öğrenme kullanımının, sığ mimarilere göre daha iyi sonuçlar vermektedir. Temelde derin öğrenme bir yapay sinir ağıdır. Derin olarak belirtilmesinin sebebi ise yapay sinir ağı yapısından kaynaklanmaktadır. İlk geliştirilen yapay sinir ağları birkaç katmandan oluşmakta iken günümüzde bu katman sayısı oldukça artmıştır. Yakın tarihlere kadar yapay sinir ağlarının eğitiminde zorluklar ortaya çıkmıştır. Teknolojinin gelişmesiyle bu zorluklar giderilerek katman sayısı arttırılmaya başlanmıştır. Bu katmanların artması ile derin ağ yapıları oluşmuştur. Derin ağlar bir, iki gizli katmana sahip sinirsel ağlardan daha iyi performans göstermektedir. Derin öğrenme ise diğer yapılara göre, karmaşık yapıdaki durumları çözme, analiz yapma, büyük veri örneklerini değerlendirmede diğer yöntemlere göre daha iyi sonuçlar vermektedir. Derin öğrenme yaklaşımları, sınıflandırma, doğal dil işleme, görüntü işleme, konuşma tanıma vb. konularda kullanılmaya uygun olup ve bu yapı basit mimarilere kıyasla daha çok çözüme yakın ve güçlü olduğu yapılan çalışmalarda belirtilmektedir (İncir, 2020).

3.4.1. Yapay sinir ağıları

İnsan zekâsına yakın hatta daha yüksek düzeyde sistemler üretme çalışmaları araştırmacıların sürekli ele aldığı bir konudur. Bu konuda ilk çalışma McCulloch ve Pitts (1943) tarafından insan beyin sinir sistemi örnek alınarak mantıksal açıdan beyin fonksiyonlarını inceleyen algoritma oluşturulmuştur. Bu çalışmalar doğrusal problemlerde etkili olmuştur.

İnsan sinir hücresi yapılarından (Şekil 3.11) esinlenilerek oluşturulan yapay sinir ağlarında, birkaç noktadan gelen sinyal değerleri ağırlık değerleri ile çarpılarak bir fonksiyonda hesaplanması ile sonuç sinyal değeri elde edilmektedir. Toplama fonksiyonu veya aktivasyon fonksiyonu sonucu çıktı olarak verilir. Bu yeni sonuç yeni katmanda yeni ağırlıklarla çarpılarak farklı bir fonksiyonun giriş değerini almaktadır.



Şekil 3.11. Nöron yapısı (Röttger, 2014)

Yapay sinir ağları aşağıdaki gibi sınıflandırılmaktadır (Sertkaya, 2018).

Yapılarına göre yapay sinir ağları:

Nöronların birbirine bağlanışına göre ileri ve geri beslemeli olarak ikiye ayrılır.

- İleri Beslemeli Ağlar: Nöronların birbirine bağlantı yönü, girişten çıkışa doğrudur. Bir katman, kendinden sonraki katmanlara bağlanmaktadır. Yapay sinir ağına girilen veriler, giriş katmanına daha sonra her birisinde işlem görerek ara katmanlara ve çıkış katmanına ulaşmaktadır.
- Geri Beslemeli Yapay Sinir Ağları: İleri beslemeli ağdakinin aksine, bir hücrenin çıktısı sadece kendinden sonraki hücre katmanına girdi olarak verilmemektedir.

Kendinden önceki katmana veya kendi katmanındaki herhangi bir hücreye de bağlanabilmektedir. Bu sebeple geri beslemeli yapay sinir ağları, doğrusal olmayan bir yapı göstermektedir.

Öğrenme algoritmalarına göre yapay sinir ağları:

Yapay sinir ağlarında esas olan ağın öğrenmesidir. Yapay sinir ağları öğrenme algoritmalarına göre danışmanlı, danışmansız ve destekli öğrenme olarak üçe ayrılır.

- **Danışmanlı Öğrenme:** Danışmanlı öğrenme sırasında ağa, giriş değerleri ile birlikte çıkış değerleri de verilmektedir. Yapay sinir ağı, verilen giriş değerleri için istenilen çıkış değerlerini oluşturabilmek için katmanlar arası ağırlıklarını güncellemektedir. Çıktılar ile beklenen çıktılar arasındaki fark hesaplanmaktadır. Ağın yeni ağırlıkları bu farka göre düzenlenmektedir. Düzenlemede her hücreye düşen hata payı hesaplanmakta ve her hücrenin ağırlıkları bu hata payına göre düzenlenmektedir.
- **Danışmansız Öğrenme:** Yapay sinir ağına, öğrenme sırasında sadece giriş verileri verilmektedir. Herhangi bir çıkış verisi verilmemektedir. Verilen bilgilere göre ağ, her bir veriyi kendi içinde sınıflandıracak şekilde kendi yapısını oluşturmaktadır. Ağ ağırlıklarını her bir iterasyonda düzenleyerek, öğrenme işlemini tamamlamaktadır.
- **Destekli Öğrenme:** Yapay sinir ağının her iterasyonunda elde ettiği sonuç, doğru veya yanlış olarak ağa bildirilmektedir. Bu bilgilere göre ağ, kendini yeniden düzenlemektedir. Ağ, hem öğrenmekte hem de sonuca ulaşmaya çalışmaktadır. Böylece ağ eğitilmiş olmaktadır. Diğer işlemlerde ağ, bu bilgilerle sonuca ulaşmaktadır.

Öğrenme zamanına göre yapay sinir ağları:

Yapay sinir ağları öğrenme zamanına göre statik ve dinamik öğrenme olarak ikiye ayrılmaktadır.


- **Statik Öğrenme:** Statik öğrenmede yapay sinir ağları, önce eğitilmektedir. Eğitimden sonra ağa test verileri girilmekte ve sonuca ulaşılmaktadır. Test aşamasında, ağın katmanları arasındaki ağırlıklarda herhangi bir değişiklik olmamaktadır.
- **Dinamik Öğrenme:** Yapay sinir ağı eğitim aşaması bittikten sonra yeni girişlerde çıkışların doğrulanmasına göre ağırlıklarını değiştirerek sonuca ulaşmayı amaçlamaktadır.

Mimari yapılarına göre derin öğrenme ağ yapıları:

- Konvolüsyonel Sinir Ağları (Evrışimli Sinir Ağları, *Convolutional Neural Networks-CNN*)
- Tekrarlayan Sinir Ağları
- Boltzman Makinesi
- Derin Oto Kodlayıcılar
- Derin İnanç Ağları
- Uzun Kısa Dönemli Bellek
- Markov Zinciri
- Destek Vektör Makinesi
- Dikkat Ağı
- Kohonen Ağı
- Aşırı Öğrenme Makineleri
- Sıvı Hal Makinesi
- Çekişmeli Üretici Ağlar

Yapay sinir hücresinin yapısı:

Biyolojik sinir hücresine benzeyen bu yapı (Şekil 3.12.) girdi, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu, çıktı kısımlarından oluşmaktadır.



Şekil 3.12. Yapay sinir hücresi yapısı

Girdiler: Girdiler hücelere verilen giriş verileridir. Bu gelen veriler ağırlıklarla işlem görerek hücreye gönderilmektedir.

Ağırlıklar: Yapay sinir hücresine verilen girdiler, bağlantının ağırlığıyla çarpılarak net kısmına iletilmektedir. Ağırlıkların değerleri pozitif, negatif veya sıfır olabilmektedir.

Toplama Fonksiyonu: Girdiler ile ağırlıkların çarpılarak diğer tüm çarpımların toplanmasıyla oluşan, o hücrenin toplam girdisinin hesaplandığı fonksiyondur.

Genel olarak fonksiyonun gösterimi Denklem 3.1’de verilmiştir.

$$Net = \sum_{i=1}^N x_i * w_i \quad (3.1)$$

Sonuç performansına göre farklı fonksiyonlarda kullanılabilir. Sonuç

Aktivasyon fonksiyonu: Toplam fonksiyonun değerlendirmeye alındığı, sonuca göre çıkış değeri üretilen fonksiyondur. Genelde Denklem 3.2’de verilen sigmoid fonksiyon kullanılmaktadır. Performansı iyileştirmek için ReLU fonksiyonu (Denklem 3.3.), basamak fonksiyonu (Denklem 3.4.) gibi farklı fonksiyonlar kullanılabilir.

Sigmoid fonksiyonu: Giriş değerlerini, 0 ve 1 aralığındaki çıkış değerine dönüştüren bir fonksiyondur. Sigmoid fonksiyonu girişteki $(-\infty, +\infty)$ aralığındaki herhangi bir değeri $(0 - 1)$ aralığındaki bir çıkış değerine dönüştürmektedir.

$$F(Net) = \frac{1}{1+e^{-Net}} \quad (3.2)$$

ReLU fonksiyonu:

$$F(Net) = \begin{cases} 0 & Net < 0 \\ Net & Net \geq 0 \end{cases} \quad (3.3)$$

Basamak fonksiyonu:


$$F(Net) = \begin{cases} 0 & Net < 0 \\ 1 & Net \geq 0 \end{cases} \quad (3.4)$$

Çok katmanlı sinir ağları girdi katmanı, ara katmanlar ve çıktı katmanından oluşmaktadır. Ağ yapısı Şekil 3.13.’te verilmiştir.

Girdi Katmanı: Yapay sinir ağına dışardan verilerin girildiği katmandır.

Ara (Gizli) Katmanlar: Giriş katmanından çıkan bilgiler bu katmana gelmektedir. Ara katman sayısı seçilen ağa göre değişebilmektedir. Ara katmanlardaki nöron sayısı giriş ve çıkış sayısından bağımsızdır. Ara katmanların ve bu katmanlardaki nöronların sayısının artması hesaplama süresini arttırmaktadır. Fakat yapay sinir ağının daha karmaşık problemleri çözmesinde fayda sağlamaktadır.

Çıktı Katmanı: Ara katmanlardan gelen bilgilerin işlendiği, ağıın çıktılarını üreten katmandır. Bu katmanda üretilen çıktılar sonuç olarak kullanıcıya verilmektedir. Geri beslemeli ağlarda bu katmanda üretilen çıktı ile ağıın yeni ağırlık deęerleri hesaplanmaktadır (Karaali ve Ülengin, 2008).




Şekil 3.13. Çok katmanlı yapay sinir ağı yapısı (Karaali ve Ülengin, 2008)

3.4.2. Evrişimli sinir ağı yapısı ve mimarisi

Yapay sinir ağları ve makine öğrenmesi programları sınıflandırmada kullanılan özel veya (XOR) işlemlerini gerçekleştiremediklerinden daha zeki sistemler uzun yıllar elde edilememiştir. 1998 yılında evrişimli sinir ağlarının bulunması ile derin öğrenme dönemi başlamıştır.

İlk konvolüsyonel sinir ağı LeNet, 1998 yılında Yann LeCun ve arkadaşları tarafından posta numaraları, banka çekleri üzerindeki el yazısı rakamlarını okumak ve sınıflandırmak için tasarlanmış beş katmanlı bir konvolüsyon ağıdır (Şekil 3.14.). 32x32 piksel gri tonlamalı giriş görüntüsünde el yazısı rakamlarını sayısallaştırma işlemini başarıyla gerçekleştirmiştir (LeCun ve ark., 1998). Birkaç banka posta numaraları, banka çekleri üzerindeki el yazısı rakamlarını okumak amacıyla kullanmıştır. Daha yüksek çözünürlüklü görüntüleri işleme yeteneği sınırlıdır (Sertkaya, 2018).

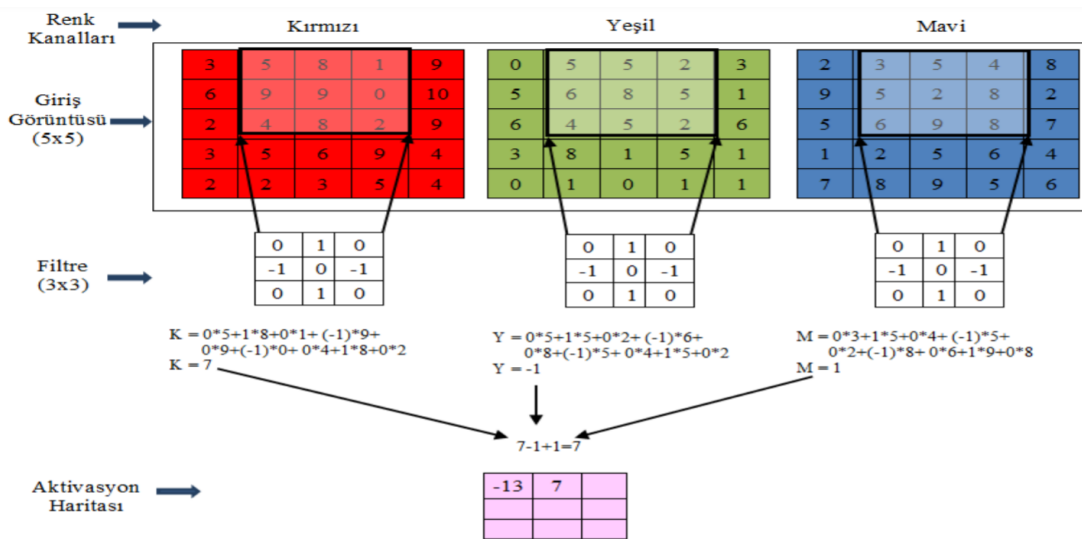


Şekil 3.14. LeNet ağ yapısı (LeCun ve ark., 1998)

ESA yapısı görüntü işlemede ve sınıflandırmada oldukça etkilidir. Katmanlarda yapılan işlemler YSA ve makine öğrenmesinin görüntü işleme için daha da özelleşmiş ESA mimarileri ile gerçekleştirilmektedir. ESA mimarisi ve katman yapıları aşağıda açıklanmıştır.

Konvolüsyon Katmanı (Convolution Layer): Ara katmanlardan olan bu katmanda evrişimin yapıldığı tabakadır. 3×3 , 5×5 boyutlarındaki filtreler görüntü üzerinde gezdirilerek konvolüsyon işlemi uygulanmaktadır. Çıkan sonuçlar ile aktivasyon haritası oluşturulmaktadır. Filtrelerin katsayıları, her öğrenme iterasyonunda değişmektedir (İnik ve Ülker, 2017).

Filtre her renk kanalında belirlenen adım (stride) değerinde ilerlemektedir. Filtredeki değerle, renk kanalındaki değer çarpılmakta ve çarpım değerleri toplanmaktadır. Diğer kanallardan gelen değerlerle toplanarak aktivasyon haritası oluşturulmaktadır (Şekil 3.14.).



Şekil 3.15. $5 \times 5 \times 3$ boyutta bir giriş görüntüsüne 3×3 'lük filtrenin uygulandığı konvolüsyon işlemi (İnik ve Ülker, 2017)

Giriş ve çıkış boyutu arasında aynı yoğunluk aralığını sağlamak için, aktivasyon haritasındaki değerler normalize edilmektedir. Her renk kanalı için hesaplanan değerler, filtre katsayılarının toplamına bölünmektedir (İnik ve Ülker, 2017).

Aktivasyon katmanı: Aktivasyon fonksiyonlarının uygulandığı katmandır. Sigmoid fonksiyonu, ReLU fonksiyonu, basamak fonksiyonu gibi fonksiyonların uygulandığı katmandır.


Düzleştirilmiş Doğrusal Birim Katmanı(*Rectified Linear Units Layer* - ReLu):

Bu katman konvolüsyon katmanlarından sonra gelmektedir.

Bu katmanda Denklem 3.5.'te verilen fonksiyon, nöronlarının çıktılarına uygulanmaktadır.

$$F(Net) = \begin{cases} 0 & Net < 0 \\ Net & Net \geq 0 \end{cases} \quad (3.5)$$


Girdilere göre fonksiyonun çıktı değerleri grafiksel olarak Şekil 3.15.'te verilmiştir.



Şekil 3.16. ReLU katmanının çıkış verisine etkisi.


Havuzlama Katmanı (*Pooling Layer*): Evrişimli sinir ağlarında, havuzlama katmanı isteğe bağlıdır. Her ağda kullanılmayabilmektedir. Amaç, sonraki konvolüsyon katmanı için genişlik ve yükseklik giriş boyutlarını azaltmaktır. Bu katman sonucu boyuttaki azalma bilgi kaybına yol açmaktadır. Bu işlem sonunda, bir sonraki ağ katmanları için daha az hesaplama yükü oluşmakta ve sistemin ezberlemesi önlenmektedir. Konvolüsyon işlemindeki gibi, havuzlama katmanında da filtre belirlenmekte ve görüntü üzerinde verilen adım değerinde gezdirilmektedir. Görüntüdeki piksellerin, maksimum değerlerini (maksimum havuzlama) veya ortalama değerlerini (ortalama havuzlama) alarak hesaplama yapılmaktadır. Genellikle performansından dolayı, maksimum havuzlama tercih edilmektedir. Havuzlama işlemi; konvolüsyon katmanından sonra hesaplanan filtre adedince, görüntülerin hepsi için hesaplanmaktadır.

Havuzlama işleminin yapılışı ile ilgili örnek uygulama Şekil 3.16.'da verilmiştir. Şekil 3.16a'da giriş görüntü boyutu 4x4 ve filtre boyutu 2x2'dir. İki adım kaydırılmakta ve oluşan her görüntünün boyutu 2x2 olmaktadır (Şekil 3.16b). Her bir filtredeki maksimum değer alınır ve sonuç (Şekil 3.16c) elde edilir (İnik ve Ülker, 2017).




Şekil 3.17. 4x4'lük giriş görüntüsüne, 2x2 filtre ile iki adım kaymalı maksimum havuzlama işlemi. a)Görüntü b) Filtre sonrası görüntü c) maksimum havuzlama işlemi sonrası görüntü.

Unutturma katmanı (*dropout layer*): Evrimsel sinir ağlarında katmanlar arasındaki bağımlılıktan dolayı değerler birbirini etkilemektedir. Bu durumda bazı ağırlıklar daha fazla değer almakta ve modele uygun hale gelmeye çalışmaktadır. Bu sabitlenmenin önüne geçmek için unutturma fonksiyonu kullanılmaktadır (Srivastava ve ark., 2014). Eğitim aşamasında rasgele seçilen nöronların bazıları ağdan çıkartılmaktadır (Şekil 3.17.). Unutturma katmanının, modelin eğitim aşamasında ezberleme (overfitting) yapmasını azaltması sebebiyle kullanımı faydalı olacaktır.



Şekil 3.18. ESA yapısı a) Standart ESA ağ yapısı b) Dropout işleminden sonra ağ yapısı

Tam bağı katman (*Fully connected / flatten layer*): Bu katman kendinden önceki katmanın tüm alanlarına bağlıdır. Bu sebepten dolayı bu katmana tam bağlantılı katman denilmektedir. Giriş değerlerini tek boyutlu bir değere dönüştürmektedir (Şekil 3.18.).



Şekil 3.19. Düzleştirme katman, tam bağlantılı katman örneği

Sınıflandırma Katmanı (*Classification Layer*): Bu katman tam bağlantılı katmandan sonra gelmektedir. Bu katmanda sınıflandırma işlemi yapılmaktadır. Bu katmanın çıkış değeri, sınıflandırması yapılacak nesne sayısına eşittir (İnik ve Ülker, 2017). Örnek olarak; on farklı nesnenin sınıflandırılması yapıldığında, sınıflandırma katmanının çıkış değeri 10 olmaktadır. Tam bağlantılı katmanda çıkış değeri 4096 olduğunda, bu çıkış değerine göre sınıflandırma katmanı için 4096×10 ağırlık matrisi elde edilmektedir. Bu katmanda farklı sınıflandırıcılar kullanılmaktadır. Genellikle softmax sınıflandırıcı tercih edilmektedir. Sınıflandırmada 10 farklı nesne 0 - 1 aralığında belli bir değerde çıkış üretmektedir. 1'e yakın olan değer, ağı tahmin değeri olarak kullanıcıya verilmektedir.

Softmax: Verileri normalleştirmek amacıyla kullanılan, bir çıkış katmanıdır. ESA modelinin çıkış katmanına gelen özellik verileri arasında seçim yapıldığı, sınıflandırma işlemi için kullanılan fonksiyondur. Softmax fonksiyonu, giriş matris verisini toplamları "1" olan bir çıktı matris yapısına dönüştürmektedir.

Ağ yapısına göre veri seti düzenlenmelidir. Düzenlemede eğitim ve test verileri hazırlanır ve ESA modeli oluşturulur. Konvolüsyon katmanı, havuzlama katmanı ve tam bağlantılı katman sayıları belirlenmektedir. Sınıflandırma katmanı seçilir ve başlangıç değişkenleri tanımlanmaktadır. İşlemi başarıya ulaştıracak; ağı öğrenme katsayısı, proses elemanlarının toplama ve aktivasyon fonksiyonları, momentum katsayısı, filtre boyutları, filtre sayısı ve adım kayma miktarı parametreleri ağı girilmektedir. Oluşturulan modele giriş verisi olarak eğitim setinden bir görüntü verilmektedir. Bu görüntü ağıdaki katmanlardan geçirilerek bir sonuç değeri elde etmektedir. Bu aşamaya ileri besleme denilmektedir. İleri beslemede her katmanda her bir filtrenin ağırlıkları ile görüntüdeki


piksel değerleri çarpılıp bunların toplamı alınarak bir sonraki katmana aktarılmaktadır. Çıkış sonuçları ve gerçek değerler Denklem 3.6'da kullanılarak toplam hata hesaplanmaktadır (İnik ve Ülker, 2017).

$$\text{Toplam Hata} = \sum_{i=1}^N \frac{1}{2} (\text{Hedef değeri} - \text{Tahmin değeri}_i)^2 \quad (3.6)$$

Elde edilen hata değeri, ağdaki bütün ağırlıklara dağıtılmaktadır. Ağırlıkların güncellenmesiyle ağın çıkışındaki toplam hata azalmaya başlamaktadır. Hata oranının azalmasıyla ağın başarı oranı artmakta, son iterasyonla gelen çıktı kullanıcıya verilmektedir.

3.4.3. AlexNet


AlexNet, 2012 yılında *The ImageNet Large Scale Visual Recognition Challenge* yarışında grafik işlemci birimi (Graphics Processing Unit-GPU) destekli Compute Unified Device Architecture'de (CUDA) yapılmış konvolüsyonel sinir ağı modelidir. Bu ağ %15.3'lük hata oranı ile yarışmada ilk beşe girmiştir. Derin öğrenmenin tekrar popüler hale gelmesini sağlayan ilk çalışmadır. Birbirini takip eden evrişim ve havuzlama katmanları bulunmasından dolayı, LeNet modeline çok benzemektedir. Aktivasyon fonksiyonu olarak ReLU, havuzlama katmanlarında da maksimum havuzlama kullanılmaktadır (Kızrak, 2018, Krizhevsky ve ark., 2012). Bu ağ 25 tabakadır. Giriş görüntü boyutları 227x227x3 'tür. Giriş, konvolüsyon, ReLU, normalizasyon, havuzlama, tam bağlantı, unutturma, softmax, sınıflandırma, çıkış tabakalarından oluşmaktadır Şekil 3.20.'de AlexNet ağ modeli ve mimari yapısı verilmiştir.



Şekil 3.20. AlexNet ağ yapısı (Krizhevsky ve ark., 2012)

3.4.4. ResNet


Ağ modelinin gerçek anlamda derinleştiği, kendinden önceki modellerden farklı özelliği barındıran ResNet (Şekil 3.21.); artık değerleri (*residual value*) sonraki katmanlara besleyen blokların (*residual block*) modele eklenmesiyle oluşturulmuştur (Kızrak, 2018). ResNet bu özelliği ile klasik öğrenme modeli olmaktan çıkmaktadır. ResNet-50, Elli katmandan oluşur. ImageNet veri tabanı ile eğitilmiştir. Görüntüleri klavye, fare, kurşun kalem, birçok hayvan türü ve diğerleriyle toplamda 1000 ayrı nesneyi kategorik sınıflandırabilmektedir (He ve ark., 2016). Şekil 3.21.'de ResNet modelinin yapısı verilmiştir.



Şekil 3.21. ResNet ağ yapısı (He ve ark., 2016)

3.4.5. GoogLeNet


GoogLeNet, yirmi iki katmanlı konvolüsyonel sinir ağıdır (Szegedy ve ark., 2016). ImageNet veri tabanı ile eğitilmiştir. GoogLeNet ağı (Şekil 3.22.), görüntüleri klavye, fare, kurşun kalem, birçok hayvan türü ve diğerleriyle toplamda 1000 ayrı nesneyi kategorik sınıflandırabilmektedir. Places365 verileriyle eğitilen ağ, ImageNet'te eğitilen ağa benzer, ancak görüntüleri alan, park, pist ve lobi gibi 365 farklı yer kategorisine sınıflandırmaktadır. Her bloğa 'inception' adı verilmektedir. Toplam 9 inception bloğundan oluşan modele, LeNet modeline atıf yapılarak GoogLeNet adı verilmiştir (Szegedy ve ark., 2016). *The ImageNet Large Scale Visual Recognition Challenge 2014* sınıflandırma yarışmasında burada dış verilerle ilgili herhangi bir eğitim almadan % 6.67'lik ilk-5 hata oranı ile birinci gelmiştir. İlk-5 hata oranı hedef etiketin ilk 5 sınıflandırma içinde olma oranıdır.



Şekil 3.22. GoogleNet ağ yapısı (İnik ve Ülker, 2017)

3.4.6. InceptionV3

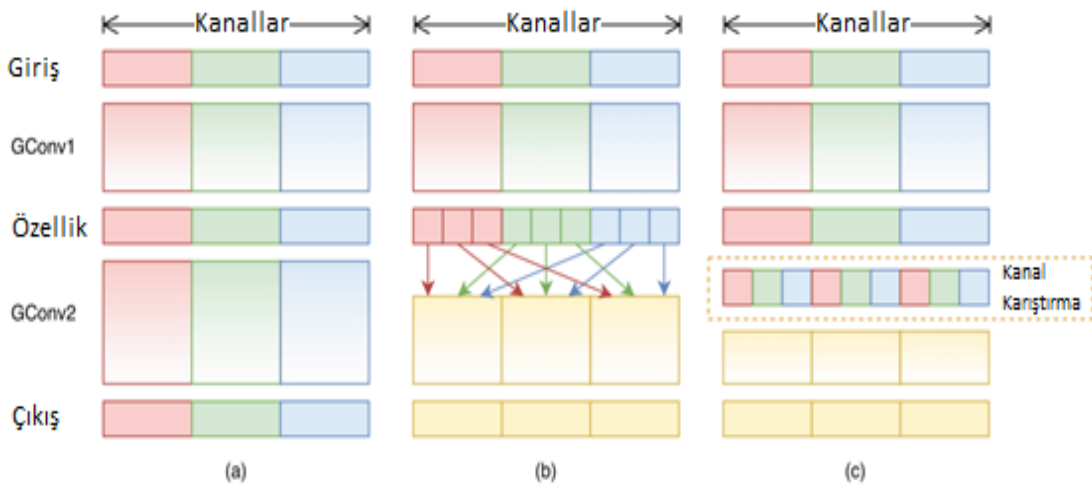
GoogLeNet'in açıklandığı makalede (Szegedy ve ark., 2016), Inception-v2 temel alınarak Inception-v3 ağını önermektedir. Inception-v3, herhangi bir $n \times n$ evrişimi $1 \times n$ evrişime ve ardından $n \times 1$ evrişime ayrıştırılmaktadır. Parametre sayısı azalmaktadır. Ağın giriş görüntü boyutları 299×299 pikseldir. 48 katmandan oluşmaktadır. ImageNet veri tabanı ile eğitilmiştir. GoogLeNet ağı gibi görüntüleri klavye, fare, kurşun kalem, birçok hayvan türü ve diğerleriyle toplamda 1000 ayrı nesneyi kategorik sınıflandırabilmektedir (Szegedy ve ark., 2016).



Şekil 3.23. Inception-V3 konvolüsyon ağ yapısı (Szegedy ve ark., 2016)

3.4.7. ShuffleNet

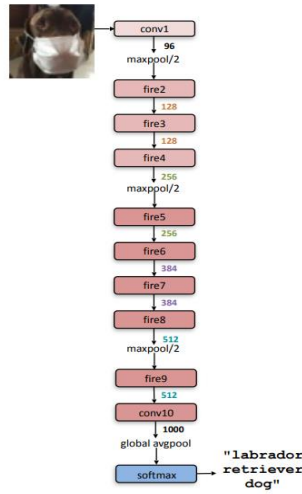
Hesaplama açısından son derece verimli bir ESA mimarisidir. Yeni mimari, doğruluğu korunurken hesaplama maliyetini büyük ölçüde azaltmak için noktasal grup evrişimi ve kanal karıştırma olmak üzere iki yeni işlem kullanmaktadır (Şekil 3.24). ImageNet sınıflandırması ve MS COCO nesne tespiti üzerindeki deneyler, ShuffleNet'in diğer yapılara göre üstün performansını gösterdiği bildirilmiştir. 40 MFLOPS'luk (*Mega Floating-point Operations Per Second*) hesaplama performansı ile ImageNet sınıflandırma görevinde hata oranı MobileNet'ten (Howard ve ark., 2017) daha düşüktür. Bir mobil cihazda ShuffleNet, karşılaştırılabilir doğruluğu korunurken AlexNet üzerinden ~13 kat gerçek hızlanma elde etmiştir (Zhang, Zhou, ve ark., 2018).



Şekil 3.24. Grup evrişimi. a) aynı sayıda gruba sahip iki küme evrişim katmanı. Her çıkış kanalı yalnızca grup içindeki giriş kanallarına bağlıdır. Çapraz bağ yok b) GConv2 ve GConv1'in farklı kümelerden çapraz bağlanması c) Kanalların çapraz bağlanarak elde edildiği Shuffle katmanı (Zhang, Zhou, ve ark., 2018).

3.4.8. SqueezeNet

Evrişimli sinir ağlarının daha disiplinli bir yaklaşıma yönelik bir çalışmadır. AlexNet'ten 50 kat daha az parametreye sahip olan ve ImageNet'te AlexNet düzeyinde doğruluğu sağlayan bir ESA mimarisidir (Şekil 3.25.). Ayrıca AlexNet'ten 510 kat daha küçük olacak şekilde sıkıştırılmıştır. Pek çok mimari aynı doğruluğa ulaşmaktadır. SqueezeNet daha az parametre ile başarıya ulaşmayı amaçlamıştır. Daha hızlı eğitilen küçük modellere olan gereksinim, kablosuz güncellemelerin artması ve veri boyutunun önemi yeni bir model üretilmesini gerektirmiştir. SqueezeNet'in bunu başardığı bildirilmiştir (Iandola ve ark., 2016).



Şekil 3.25. SqueezeNet ağ yapısı (Iandola ve ark., 2016)

3.4.9. Çapraz Doğrulama ve Performans Kriterleri

Bu tez çalışmasında, ISLES ve RSNA veri kümelerinden elde edilen veriler kullanılarak bölüm 3.4.3-3.4.8 arasında tanımlanan altı farklı derin öğrenme modeli ile üç sınıflı çıkışların (iskemi, kanama, normal) performansları değerlendirilmiştir. Literatür taramasında incelenen çalışmalarda kullanılan sınıflandırma performans kriterleri detaylı bir şekilde araştırılmış ve tez çalışmasında kullanılmıştır. Tüm işlemler Intel Core İ7-7700HQ Cpu 2.80 GHz, 16 GB Ram, NVIDIA GeForce GTX 1050 Ti 8 GB ekran kartlı x64 bit Windows işletim sisteminde çalışan Matlab R2021a programı ile yapılmıştır. PNG formatındaki görüntüler her model için varsayılan özelliklerde işleme alınmıştır. Modellerin bir biriyle karşılaştırılması amaçlanmaktadır. Programların çalışmasında hafıza yetersizliği hataları alınması üzerine, tüm programların en iyi performansta çalıştığı parametreler belirlenmiştir. Bu parametreler kullanılarak işlemler gerçekleştirilmiştir.

Görüntülere yansıtma, 30 piksele kadar x yönünde ve y yönünde rastgele çevirme metotları ile veri çoğaltma yapılmıştır. Tek katman olan BT görüntüsü, ağların $N \times N \times 3$ yapısından dolayı diğer katmanlara da eklenmiştir.

Tez çalışmasında çıkış performanslarını değerlendirmek için veri kümelerinde 5 kat çapraz geçişleme kullanılmıştır. Kullanılan veriler %80 eğitim, %20 test verisi olarak beş parçaya bölünmüş, her döngüde bir alan test verisi diğer dördü eğitim verisi olarak kullanılmıştır. Böylece tüm veri içerisindeki görüntüler eğitim ve test işleminde

kullanılarak 5 kat çapraz geçeleme sonucu elde edilen performans değerlerinin ortalaması hesaplanmıştır. Çizelge 3.1.'de 5 kat çapraz geçeleme için kullanılan veri dağılımının tablo şeklinde gösterimi verilmiştir.

Çizelge 3.1. Beş kat çapraz geçeleme tablosu

| | 1. Veri kümesi | 2. Veri kümesi | 3. Veri kümesi | 4. Veri kümesi | 5. Veri kümesi |
|----------|----------------|----------------|----------------|----------------|----------------|
| 1. Döngü | Test | Eğitim | Eğitim | Eğitim | Eğitim |
| 2. Döngü | Eğitim | Test | Eğitim | Eğitim | Eğitim |
| 3. Döngü | Eğitim | Eğitim | Test | Eğitim | Eğitim |
| 4. Döngü | Eğitim | Eğitim | Eğitim | Test | Eğitim |
| 5. Döngü | Eğitim | Eğitim | Eğitim | Eğitim | Test |

Çapraz geçeleme kullanılarak eğitim ve test olarak ayrılan veriler derin öğrenme modellerine girdi olarak verilmiştir. Eğitim işleminin bitmesi ile beraber test verileri performans ölçümü için model çıktısının karmaşıklık matrisi elde edilmiştir. Karmaşıklık matrisi üç sınıf olduğu için üç satır ve üç sütundan oluşmaktadır. Çizelge 3.2.'de her döngü sonucunda elde edilen karmaşıklık matrisi modeli verilmiştir.

Çizelge 3.2. Karmaşıklık matrisi

| | | Tahmin | | |
|--------|--------|----------|----------|----------|
| | | İskemi | Kanama | Normal |
| Gerçek | İskemi | G_{ii} | G_{iK} | G_{iN} |
| | Kanama | G_{Ki} | G_{KK} | G_{KN} |
| | Normal | G_{Ni} | G_{NK} | G_{NN} |

Çizelge 3.2'deki satır ve sütunlardaki kısaltmaların açıklaması şu şekildedir:

G_{ii} : Doğru sınıflandırılmış iskemi görüntü sayısı

G_{KK} : Doğru sınıflandırılmış kanama görüntü sayısı

G_{NN} : Doğru sınıflandırılmış normal beyin görüntü sayısı

G_{iK} : İskemi görüntüsü iken, kanama olarak yanlış sınıflandırılmış görüntü sayısı

G_{iN} : İskemi görüntüsü iken, normal beyin olarak yanlış sınıflandırılmış görüntü sayısı

G_{Ki} : Kanama görüntüsü iken, iskemi olarak yanlış sınıflandırılmış görüntü sayısı

G_{KN} : Kanama görüntüsü iken, normal beyin olarak yanlış sınıflandırılmış görüntü sayısı

G_{Ni} : İskemi görüntüsü iken, iskemi olarak yanlış sınıflandırılmış görüntü sayısı

G_{NK} : Normal beyin görüntüsü iken, kanama olarak yanlış sınıflandırılmış görüntü sayısı

Karmaşıklık matrisinde açıklanan ifadeler kullanılarak sistem performans hesaplanması için TP, FP, FN, TN değerleri elde edilmiştir. Bu ifadelerin üç sınıflı bir karmaşıklık matrisi için hesaplama metotları aşağıda sırasıyla belirtilmiştir. Doğru Pozitif (DP) - *True Positive* (TP): Gerçekte pozitif olan verilerin, pozitif olarak sınıflandırılanlarının sayısıdır. Doğru sınıflanmış görüntü sayısı toplamıdır (Denklem 3.7).

$$TP = G_{ii} + G_{KK} + G_{NN} \quad (3.7)$$

İskemi sınıfı hesaplamalarında; birinci grup iskemi görüntüleri ikinci grup iskemi olmayan görüntülerden oluşmaktadır. Kanama ve normal beyin görüntüleri iskemi olmadığı için tek sınıf sayılmaktadır.

Kanama sınıfı hesaplamalarında; birinci grup kanama görüntüleri ikinci grup kanama olmayan görüntülerden oluşmaktadır. İskemi ve normal beyin görüntüleri kanama olmadığı için tek sınıf sayılmaktadır.

Normal beyin görüntü sınıfı hesaplamalarında; birinci grup normal görüntüleri ikinci grup normal olmayan görüntülerden oluşmaktadır. Kanama ve iskemi beyin görüntüleri normal beyin görüntüsü olmadığı için tek sınıf sayılmaktadır.

Yanlış Pozitif (YP) – *False Positive* (FP): Gerçekte negatif olan verilerin pozitif olarak sınıflananlarının sayısıdır.

FP_i : Programın iskemi olarak sınıflandırdığı fakat gerçekte kanama ve normal beyin görüntülerinin toplamıdır (Denklem 3.8).

FP_K : Programın kanama olarak sınıflandırdığı fakat gerçekte iskemi ve normal beyin görüntülerinin toplamıdır (Denklem 3.9).

FP_N : Programın normal beyin görüntüsü olarak sınıflandırdığı fakat gerçekte iskemi ve kanama toplamıdır (Denklem 3.10).

$$FP_i = G_{Ki} + G_{Ni} \quad (3.8)$$

$$FP_K = G_{iK} + G_{NK} \quad (3.9)$$

$$FP_N = G_{iN} + G_{KN} \quad (3.10)$$

Yanlış Negatif (YN) - *False Negative* (FN): Gerçekte pozitif olan verilerin negatif olarak

sınıflandırılan sayıdır.

FN_i : Gerçekte iskemi sınıfında olan fakat programın kanama ve normal beyin olarak sınıflandırdığı görüntülerinin toplamıdır (Denklem 3.11).

FN_K : Gerçekte kanama olan fakat programın iskemi ve normal beyin olarak sınıflandırdığı görüntülerinin toplamıdır (Denklem 3.12).

FN_N : Gerçekte normal beyin görüntüsü olan fakat programın iskemi ve kanama olarak sınıflandırdığı görüntülerin toplamıdır (Denklem 3.13).

$$FN_i = G_{iK} + G_{iN} \quad (3.11)$$

$$FN_K = G_{Ki} + G_{KN} \quad (3.12)$$

$$FN_N = G_{Ni} + G_{NK} \quad (3.13)$$

Doğru Negatif (DN) – *True Negative* (TN): Gerçekte negatif olan verilerin negatif olarak sınıflananlarının sayısıdır. Üç grup veri iki gruba indirgenerek hesaplama yapılmaktadır. İskemik inme, kanama ve normal beyin görüntüleri doğru negatif hesaplamaları için denklemler sırasıyla Denklem 3.14, Denklem 3.15 ve Denklem 3.16’da verilmiştir.

$$TN_i = G_{KK} + G_{KN} + G_{NK} + G_{NN} \quad (3.14)$$

$$TN_K = G_{ii} + G_{iN} + G_{Ni} + G_{NN} \quad (3.15)$$

$$TN_N = G_{KK} + G_{Ki} + G_{iK} + G_{ii} \quad (3.16)$$

Üç sınıflı model için hesaplanan TP, FP, FN, TN değerleri kullanılarak hassasiyet (Precision), duyarlılık / geri çağırma (Recall), F1 puanı, doğruluk (Accuracy) değerleri hesaplanmıştır.

Doğruluk: Ağın doğru olarak sınıflandırdığı görüntü sayılarının toplam tahmin sayısına oranını göstermektedir (Denklem 3.18).

Tüm görüntülerin sayısı Denklem 3.17’de verilmiştir.

$$\text{Tüm Görüntülerin Sayısı: } G_{ii} + G_{iN} + G_{iK} + G_{Ki} + G_{KK} + G_{KN} + G_{Ni} + G_{NK} + G_{NN} \quad (3.17)$$

$$\text{Doğruluk: } \frac{TP}{\text{Tüm Görüntülerin Sayısı}} \quad (3.18)$$

Geri Çağırma (*Recall*) / Duyarlılık (*Sensitivity*) / TPR: Sınıflandırıcı tarafından doğruların, pozitif ve doğru olarak etiketlenmiş örneklere oranıdır (Denklem 3.22). Bu

oran başarılı derin öğrenme algoritmalarında yüksek olmaktadır. Geri çağırma aynı zamanda Doğru pozitif oranını (TPR) ve duyarlılığı ifade etmektedir. Duyarlılık -TPR oranları sırasıyla iskemi, kanama ve normal beyin görüntüleri için Denklem 3.19, Denklem 3.20 ve Denklem 3.21’de verilmiştir. FPR oranları sırasıyla iskemi, kanama ve normal beyin görüntüleri için Denklem 3.24, Denklem 3.25 ve Denklem 3.26’da verilmiştir. ROC-AUC grafiği çiziminde ve hesaplamalarında iskemi için Denklem 3.19 ve 3.24, kanama için Denklem 3.20 ve 3.25 normal beyin görüntüsü için Denklem 3.21 ve 3.26 kullanılmaktadır.

$$\text{Recall}_{\text{İskemi}} : \frac{G_{ij}}{G_{ij} + FN_i} \quad (3.19)$$

$$\text{Recall}_{\text{Kanama}} : \frac{G_{KK}}{G_{KK} + FN_K} \quad (3.20)$$

$$\text{Recall}_{\text{Normal}} : \frac{G_{NN}}{G_{NN} + FN_N} \quad (3.21)$$

$$\text{Duyarlılık / TPR} : \frac{\text{Recall}_{\text{İskemi}} + \text{Recall}_{\text{Kanama}} + \text{Recall}_{\text{Normal}}}{3} \quad (3.22)$$

FPR: Yanlış pozitif oranı.

$$\text{FPR} = 1 - \text{Özgüllük} \quad (3.23)$$

$$\text{FPR}_{\text{İskemi}} : \frac{FP_i}{FP_i + TN_i} \quad (3.24)$$

$$\text{FPR}_{\text{Kanama}} : \frac{FP_K}{FP_K + TN_K} \quad (3.25)$$

$$\text{FPR}_{\text{Normal}} : \frac{FP_N}{FP_N + TN_N} \quad (3.26)$$

Kesinlik (*Precision*) : Doğruların, doğru ve pozitif verilerin toplam sayısına oranıdır. İskemi, kanama ve normal beyin görüntüleri için kesinlik denklemleri sırasıyla Denklem 3.27, Denklem 3.28 ve Denklem 3.29’da verilmiştir. Ortalama kesinlik, Denklem 3.30 ile hesaplanmaktadır.

$$\text{Precision}_{\text{İskemi}} : \frac{G_{ij}}{G_{ij} + FP_i} \quad (3.27)$$

$$\text{Precision}_{\text{Kanama}} : \frac{G_{KK}}{G_{KK} + FP_K} \quad (3.28)$$

$$\text{Precision}_{\text{Normal}} : \frac{G_{NN}}{G_{NN} + FP_N} \quad (3.29)$$

$$\text{Kesinlik} : \frac{\text{Precision}_{\text{İskemi}} + \text{Precision}_{\text{Kanama}} + \text{Precision}_{\text{Normal}}}{3} \quad (3.30)$$

Özgüllük (*Specificity*) : Gerçek durumu negatif olan görüntülerin ne kadarının doğru şekilde tespit edildiğini göstermektedir. Ortalama özgüllük, Denklem 3.34 ile hesaplanmaktadır. İskemi, kanama ve normal beyin görüntüleri için özgüllük denklemleri sırasıyla Denklem 3.31, Denklem 3.32 ve Denklem 3.33'te verilmiştir

$$\text{Özgüllük}_{\text{İskemi}} : \frac{TN_I}{TN_I + FP_I} \quad (3.31)$$

$$\text{Özgüllük}_{\text{Kanama}} : \frac{TN_K}{TN_K + FP_K} \quad (3.32)$$

$$\text{Özgüllük}_{\text{Normal}} : \frac{TN_N}{TN_N + FP_N} \quad (3.33)$$

$$\text{Özgüllük} : \frac{\text{Özgüllük}_{\text{İskemi}} + \text{Özgüllük}_{\text{Kanama}} + \text{Özgüllük}_{\text{Normal}}}{3} \quad (3.34)$$

F1 puanı kesinlik ve duyarlılığın harmonik ortalamasıdır. Eşit dağılımın olmadığı veri kümelerinde doğrulukla birlikte değerlendirilerek aşırı uçların sonucu ne oranda etkilediği gösterilmektedir. F1 skoru Denklem 3.35 ile hesaplanmaktadır.

$$\text{F1 puanı} : \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.35)$$

Çalışmada 5 çapraz geçirme kullanıldığı için, algoritmalar beş döngü olarak koşturulmuştur. Her döngüde Hassasiyet, duyarlılık / geri çağırma, F1 puanı, doğruluk değerleri hesaplanmıştır. Alınan değerler toplanıp beşe bölünmüş ve standart sapmaları elde edilmiştir. Her veri hem test hem de eğitimde kullanıldığı için sonucun ortalama hesabıyla, homojen ve daha hassas doğruluk değerine ulaşılmıştır.

Tez çalışmasında kullanılan diğer performans kriteri ROC eğrisi altında kalan alanı belirten ROC-AUC değeridir. ROC (*Receiver Operating Characteristics*) eğrisi performans incelemelerinde kullanılan grafiklerdendir. AUC (*Area Under the Curve* – Eğri altında kalan alan) değerinin 1 olması performansın %100 olduğunu, sınıflandırmanın tam yapıldığını göstermektedir. Grafik, her sınıfın TPR değerine karşılık

gelen FPR değeri ile çizilmektedir. ROC bir olasılık eğrisidir ve AUC, ayrıştırmanın ölçüsünü göstermektedir (Narkhed, 2018).


Landgrebe ve Duin (2008), çok sınıflı ROC yaklaşımını ele aldıkları çalışmalarında; 40 sınıfa kadar verinin sınıflandırma performansını değerlendirmektedir. İki ayrılmış grup arasında yalnızca küçük bir etkileşim derecesi varsa, performans üzerinde önemli bir etkisi olmadığı için etkileşimin göz ardı edilebileceği gösterilmektedir. İki sınıflı ROC analizinde kullanılan hesaplamaları çok sınıflı problemlere genelleştirerek, gelecekteki önemli çalışmaların temelini oluşturabileceği öne sürülmüştür (Landgrebe ve Duin, 2008). Bu çalışma perspektifinde üç sınıflı, iki sınıfa indirgeyerek ROC-AUC hesaplamaları yapılmıştır.

İskemi sınıfı ROC-AUC hesaplamalarında; İskemi (pozitif) durumuna karşı iskemi olmayan durum (negatif - kanama ve normal beyin görüntüsü) karşılaştırılmaktadır.

Kanama sınıfı ROC-AUC hesaplamalarında; Kanama (pozitif) durumuna karşı kanama olmayan durum (negatif - iskemi ve normal beyin görüntüsü) karşılaştırılmaktadır.

Normal beyin görüntü sınıfı ROC-AUC hesaplamalarında; Normal beyin görüntüsü (pozitif) durumuna karşı normal beyin görüntüsü olmayan durum (negatif - kanama ve iskemi) karşılaştırılmaktadır.

Örnek olarak Şekil 3.26.'da AlexNet 1. Döngü ROC grafiği verilmiştir. Her sınıf kendi içerisinde değerlendirilmektedir. Şekil 3.27. karmaşıklık matrisinde verildiği üzere; program 57 iskemi görüntüsünün 1 âdetini kanama sınıfında tahmin etmiştir. İskemi sınıflandırma oranının diğer sınıflandırmalardan daha yüksek olduğu verilmiştir. Bunu grafiksel olarak gösterecek olan Şekil 3.26.'daki ROC grafiği incelendiğinde, iskemi ROC-AUC değeri 0.998 ile diğer sınıflandırma ROC-AUC değerlerinden daha yüksektir. Bu karşılaştırma ile performans görsel ve matematiksel olarak ortaya çıkmaktadır.



Şekil 3.26. AlexNet 1. Döngü ROC grafiği

| | | | | |
|--------------------------|--------|---------------------|--------|--------|
| Görüntünün gerçek sınıfı | iskemi | 56 | 1 | |
| | kanama | 1 | 53 | 2 |
| | normal | 3 | 5 | 59 |
| | | iskemi | kanama | normal |
| | | Tahmin edilen sınıf | | |

Şekil 3.27. AlexNet 1. Döngü karmaşıklık matrisi

Çizelge 3.3'te ağ yapılarının örnek özellik tablosu verilmiştir. Özelliklerin açıklamaları aşağıdadır.

Çizelge 3.3. Örnek ağ eğitim özellikleri tablosu

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 7 |
| MiniBatchSize | 20 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |

Momentum: Ađın dođruyu bulma amacıyla yaptıđı hesaplamalarda bir parametre olarak verilmektedir. Salınımın azalmasıyla dođru sonucu bulma hızı artmaktadır.

InitialLearnRate: Öğrenme hızı.

MiniBatchSize: Büyük veri gruplarının işlenmesi bellek yetersizliklerinden sebep olabilmektedir. Veriler daha küçük parçalara ayrılarak işleme tabi tutulmaktadır. Bu deđer, bir seferde kaç veriyi işleme alacağını göstermektedir.

Shuffle: Katmanları karışırma.

ExecutionEnvironment: İşlemin yapıldığı işlemci.

BatchNormalizationStatistics: Normalizasyonun yapıldığı metot.



4. ARAŞTIRMA BULGULARI VE TARTIŞMA

4.1. AlexNet Sınıflandırma Sonuçları

5 kat çapraz geçişleme kullanılarak AlexNet ile yapılan denemelerde ağ parametreleri Çizelge 4.1.'de ve her döngü için elde edilen sınıflandırma sonuçları Çizelge 4.2.'de verilmiştir.

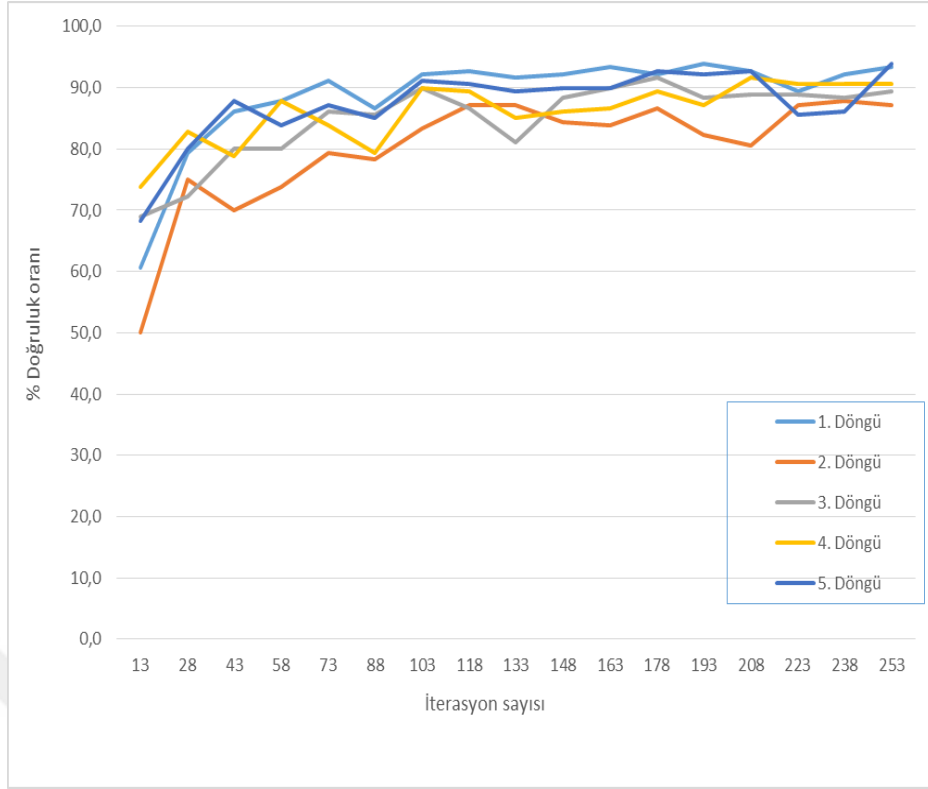
Çizelge 4.1. AlexNet ağ eğitim özellikleri

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 7 |
| MiniBatchSize | 20 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |

Çizelge 4.2. AlexNet performans değerleri

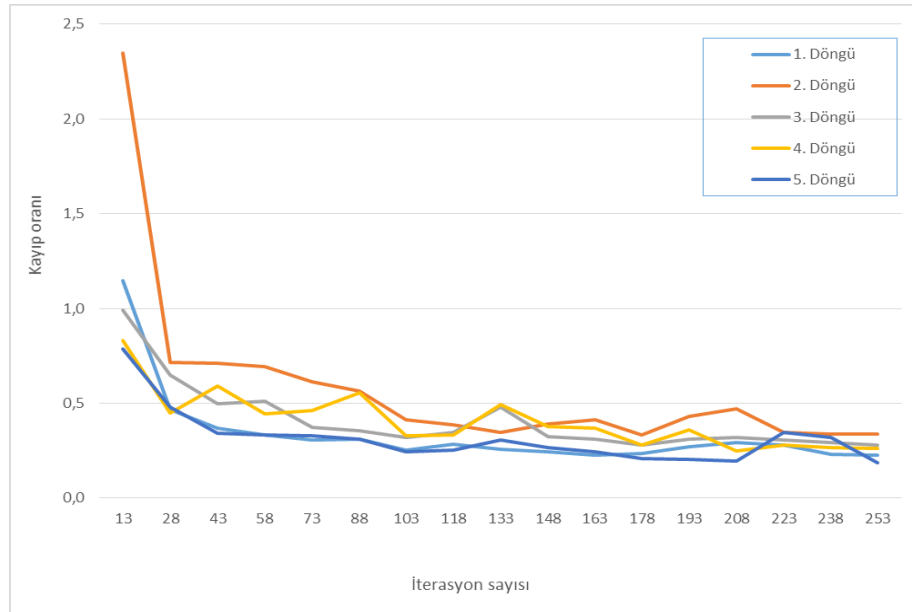
| Döngü | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Süre (sa:d:s) |
|----------|-------------|-------------|-------------|-------------|---------------|
| 1.Döngü | 0.9330 | 0.9365 | 0.9347 | 0.9333 | 00:04:19 |
| 2.Döngü | 0.8700 | 0.8711 | 0.8706 | 0.8722 | 00:04:19 |
| 3.Döngü | 0.8985 | 0.8912 | 0.8949 | 0.8944 | 00:04:22 |
| 4.Döngü | 0.9042 | 0.9127 | 0.9084 | 0.9056 | 00:04:17 |
| 5.Döngü | 0.9374 | 0.9369 | 0.9371 | 0.9389 | 00:04:20 |
| Ortalama | 0.9086±0.02 | 0.9097±0.02 | 0.9091±0.02 | 0.9089±0.02 | 00:04:19 |

Çizelge 4.2'de verilen AlexNetin performans değerlerindeki 0.90 üzeri değerler performansın yüksek olduğunu göstermektedir. Her döngünün süresi ~4 dakikadır. Toplam süre 21 dakika 37 saniyedir. Bu süre zaman kaybı noktasında tam sınırdadır.



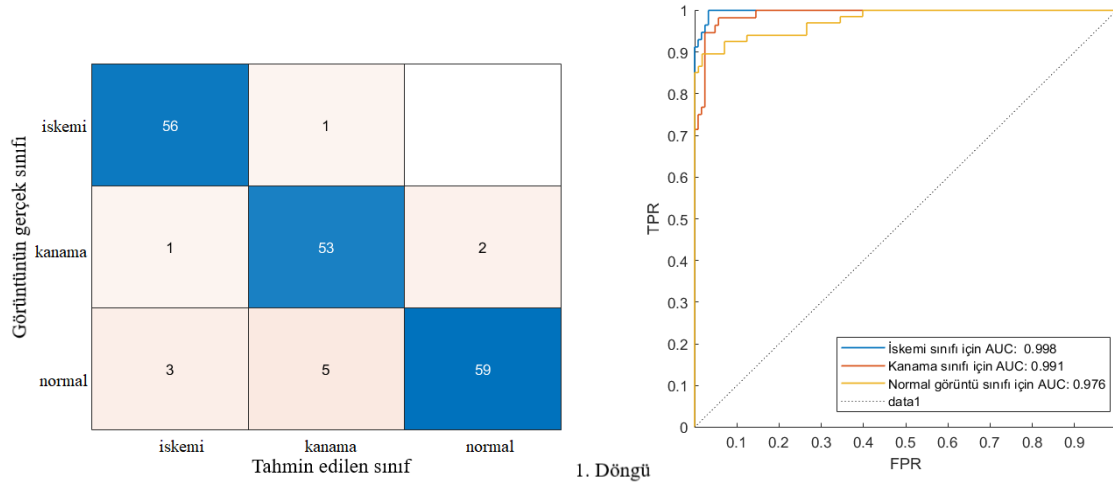
Şekil 4.1. AlexNet beş döngünün % doğruluk grafiği

Şekil 4.1.'de, tüm döngülerde kısa sürede doğruluk oranı hızla yükselmiştir. İşlemin yarısına ulaşılmadan 2. Döngü hariç diğer döngülerde yaklaşık %90 doğruluk oranına yaklaşılmıştır. 220. İterasyondan sonra ağ kararlı duruma gelmiştir.



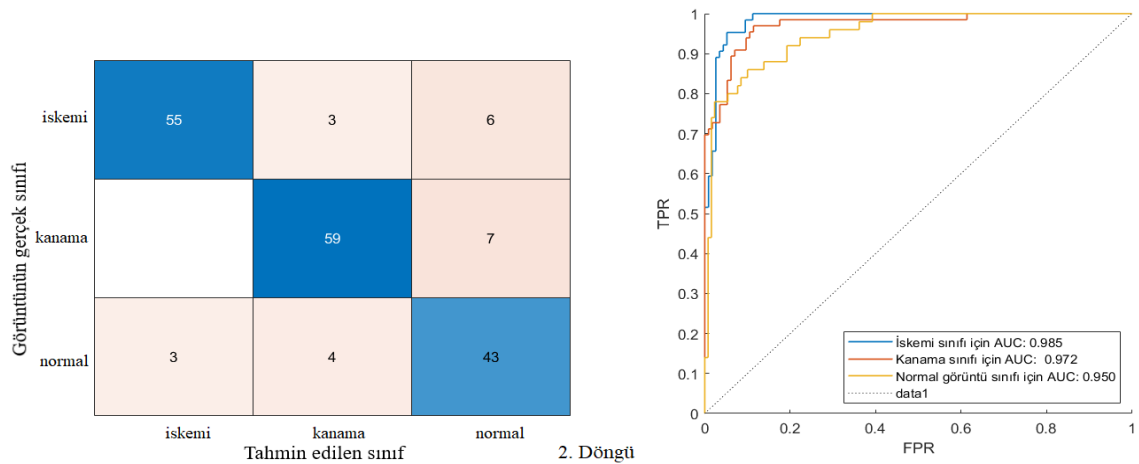
Şekil 4.2. AlexNet beş döngünün kayıp oranı grafiği

Şekil 4.2’de, tüm döngülerde tahmin edilen değer ile gerçek değer arasındaki hata değerinin kısa sürede azalması ile kayıp oranı hızla düşmüştür. İşlemin yarısına varmadan yaklaşık 0.4 kayıp oranına yaklaşılmıştır. 220. İterasyondan sonra ağ kararlı duruma gelmiştir.



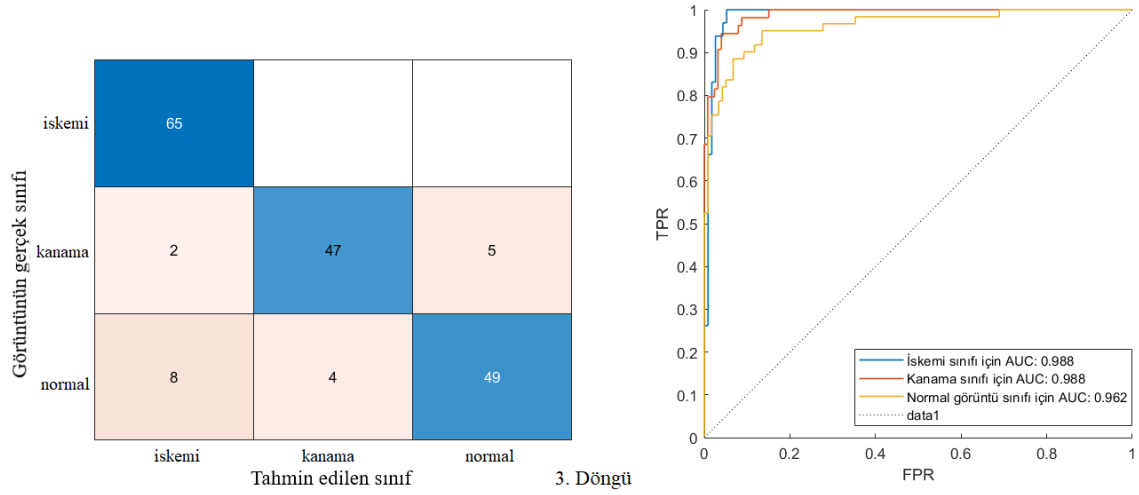
Şekil 4.3. AlexNet 1. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.3’te 56 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.998 ile en yüksek değerdedir. 53 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır. 2 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.991’dir. 2. En iyi sınıflandırma değeridir. 59 normal beyin görüntüsü doğru sınıflanmıştır. 3 normal görüntü iskemi görüntüsü olarak, 5 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.976 ile en düşük değerdedir.



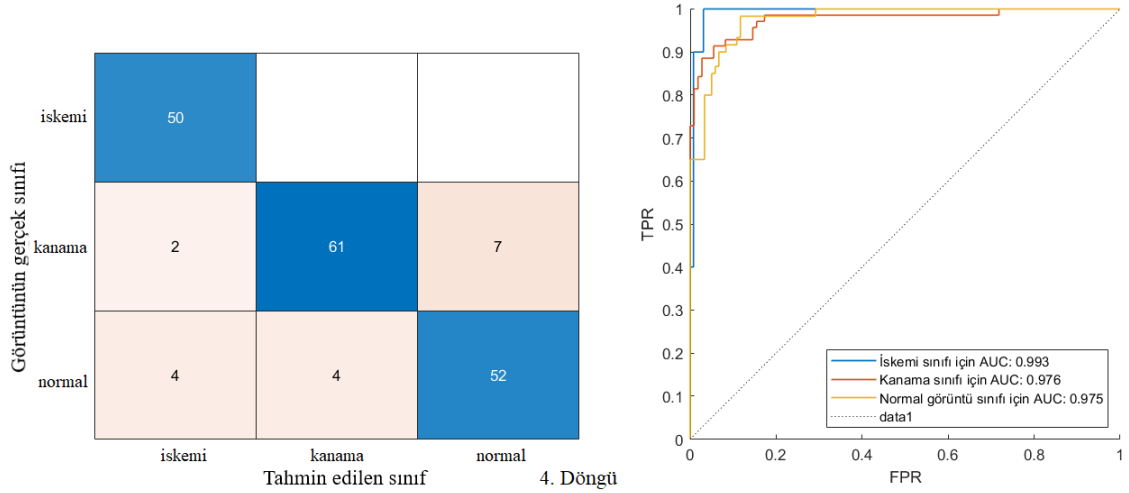
Şekil 4.4. AlexNet 2. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.4'te 55 iskemi görüntüsü doğru sınıflanmıştır. 3 iskemi görüntüsü kanama olarak sınıflanmıştır. 6 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.985 ile en yüksek değerdedir. 59 kanama görüntüsü doğru sınıflanmıştır. 7 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.972'dir. 2. En iyi sınıflandırma değeridir. 43 normal beyin görüntüsü doğru sınıflanmıştır. 3 normal görüntü iskemi görüntüsü olarak, 4 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.950 ile en düşük değerdedir.



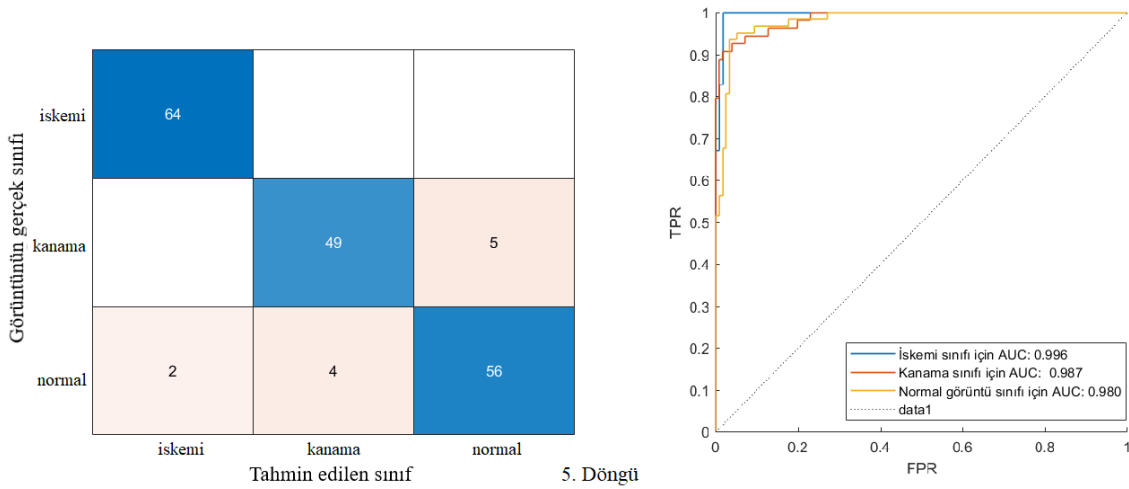
Şekil 4.5. AlexNet 3. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.5'te 65 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.988 ile en yüksek değerdedir. 47 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 5 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.988'dir. 2. En iyi sınıflandırma değeridir. 49 normal beyin görüntüsü doğru sınıflanmıştır. 8 normal görüntü iskemi görüntüsü olarak, 4 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.962 ile en düşük değerdedir.



Şekil 4.6. AlexNet 4. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.6’da 50 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.993 ile en yüksek değerdedir. 61 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 7 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.976’dır. 2. En iyi sınıflandırma değeridir. 52 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 4 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.975 ile en düşük değerdedir.



Şekil 4.7. AlexNet 5. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.7’de 64 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.996 ile en yüksek değerdedir. 49 kanama görüntüsü doğru sınıflanmıştır. 5 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.987’dir. 2. En iyi sınıflandırma

değeridir. 56 normal beyin görüntüsü doğru sınıflanmıştır. 2 normal görüntü iskemi görüntüsü olarak, 4 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.980 ile en düşük değerdedir.

Çizelge 4.3. AlexNet ROC-AUC değerleri ve beş döngü ortalaması

| | Döngü | İskemi | Kanama | Normal |
|---------------------------------|----------|-------------|--------------|--------------|
| AlexNet ROC-AUC değerleri | 1. Döngü | 0.998 | 0.991 | 0.976 |
| | 2. Döngü | 0.985 | 0.972 | 0.950 |
| | 3. Döngü | 0.988 | 0.988 | 0.962 |
| | 4. Döngü | 0.993 | 0.976 | 0.975 |
| | 5. Döngü | 0.996 | 0.987 | 0.980 |
| | Ortalama | 0.992±0.005 | 0.9828±0.008 | 0.9686±0.012 |

4.2. ResNet-50 Sınıflandırma Sonuçları

Beş kat çapraz geçişleme kullanılarak ResNet-50 ile yapılan denemelerde ağ parametreleri Çizelge 4.4.'te ve her döngü için elde edilen sınıflandırma sonuçları Çizelge 4.5.'te verilmiştir.


Çizelge 4.4. ResNet-50 ağ eğitim özellikleri

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 7 |
| MiniBatchSize | 10 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |

Çizelge 4.5. ResNet-50 ağ performans değerleri


| Döngü | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Süre (sa:d:s) |
|----------|-------------|-------------|-------------|-------------|---------------|
| 1.Döngü | 0.9133 | 0.9039 | 0.9086 | 0.9056 | 00:12:36 |
| 2.Döngü | 0.9034 | 0.9043 | 0.9039 | 0.9056 | 00:31:33 |
| 3.Döngü | 0.9216 | 0.9207 | 0.9212 | 0.9222 | 00:34:39 |
| 4.Döngü | 0.8925 | 0.8949 | 0.8937 | 0.8833 | 00:38:36 |
| 5.Döngü | 0.9152 | 0.9167 | 0.9159 | 0.9167 | 00:35:59 |
| Ortalama | 0.9092±0.01 | 0.9081±0.01 | 0.9086±0.01 | 0.9067±0.01 | 00:30:41 |

Çizelge 4.5'te verilen ResNet-50 ağ performans değerlerinin 0.90 üzeri değerler olması performansın yüksek olduğunu göstermektedir. Döngü süreleri ~30 dakikadır. Toplam süre 2 saat 33 dakika 23 saniyedir. Bu süre zaman kaybı noktasında hasta hayatını tehlikeye atacaktır sürededir. Her ne kadar performans değerleri yüksek olsa da zaman faktöründen dolayı teşhiste kullanılması uygun değildir.




Şekil 4.8. ResNet-50 beş döngünün % doğruluk grafiği

Şekil 4.8'de, tüm döngülerde doğruluk oranı hızla yükselmiştir. İşlemin yarısına varıldığında kararlı bir hale geçilse de başarı oranı %90'ın altındadır. 430. İterasyondan sonra %90 doğruluk oranına yaklaşılmıştır.



Şekil 4.9. ResNet-50 beş döngünün kayıp oranı grafiği

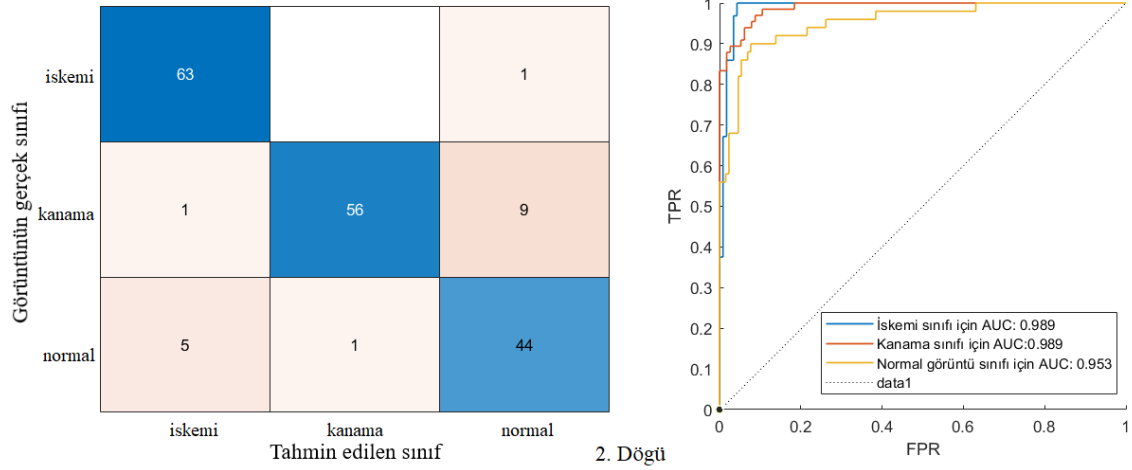
Şekil 4.9’da, tüm döngülerde tahmin edilen değer ile gerçek değer arasındaki hata değerinin kısa sürede azalması ile kayıp oranı hızla düşmüştür. İşlemin yarısına varmadan yaklaşık 0.35 kayıp oranına yaklaşılmıştır. 430. İterasyondan sonra ağ kararlı duruma gelmiştir.



Şekil 4.10. ResNet-50 1. Döngü karmaşıklık matrisi ve ROC grafiği

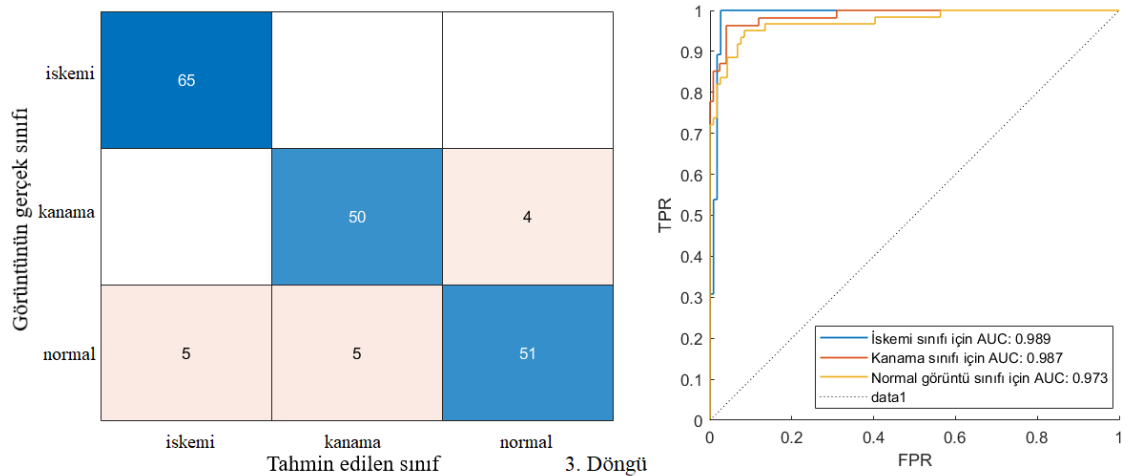
Şekil 4.10’da 55 iskemi görüntüsü doğru sınıflanmıştır. 2 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.989 ile en yüksek değerdedir. 46 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır.

9 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.988'dir. 2. En iyi sınıflandırma değeridir. 62 normal beyin görüntüsü doğru sınıflanmıştır. 3 normal görüntü iskemi görüntüsü olarak, 2 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.968 ile en düşük değerdedir.



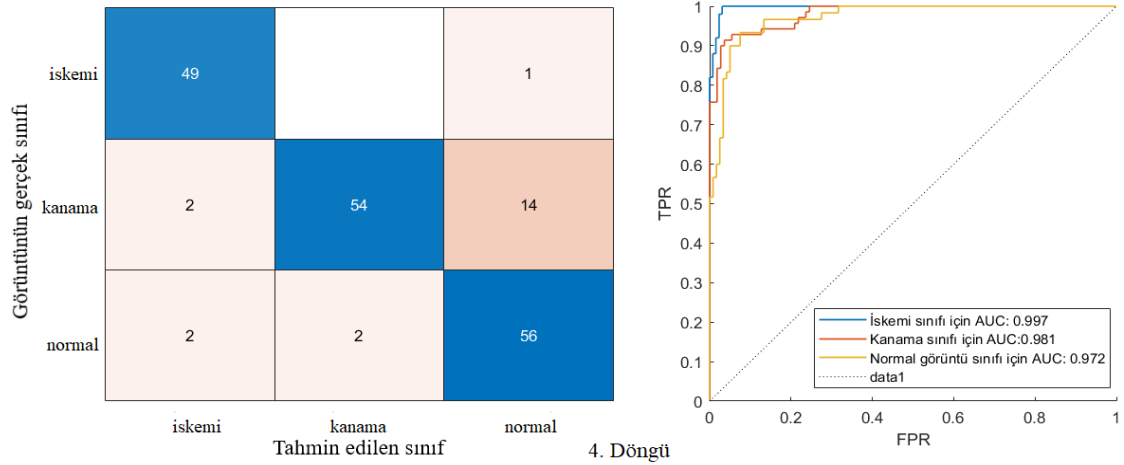
Şekil 4.11. ResNet-50 2. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.11'de 63 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.989'dur. 56 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır. 9 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.989'dur. 44 normal beyin görüntüsü doğru sınıflanmıştır. 5 normal görüntü iskemi görüntüsü olarak, 1 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.953 ile en düşük değerdedir.



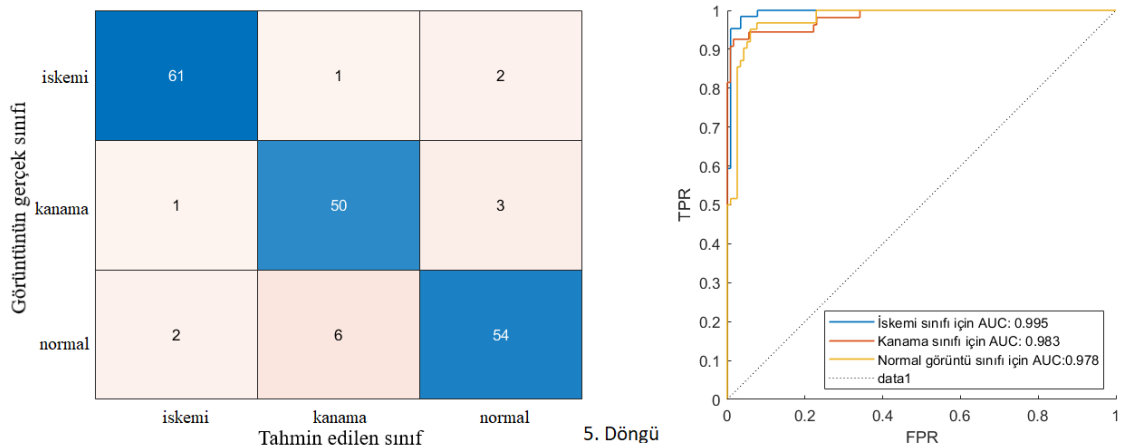
Şekil 4.12. ResNet-50 3. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.12’de 65 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.989 ile en yüksek değerdedir. 50 kanama görüntüsü doğru sınıflanmıştır. 4 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.987’dir. 2. En iyi sınıflandırma değeridir. 51 normal beyin görüntüsü doğru sınıflanmıştır. 5 normal görüntü iskemi görüntüsü olarak, 5 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.973 ile en düşük değerdedir.



Şekil 4.13. ResNet-50 4. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.13’te 49 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.997 ile en yüksek değerdedir. 54 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 14 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.981’dir. 2. En iyi sınıflandırma değeridir. 56 normal beyin görüntüsü doğru sınıflanmıştır. 2 normal görüntü iskemi görüntüsü olarak, 2 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.972 ile en düşük değerdedir.



Şekil 4.14. ResNet-50 5. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.14'te 61 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. 2 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.995 ile en yüksek değerdedir. 50 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır. 3 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.983'tür. 2. En iyi sınıflandırma değeridir. 54 normal beyin görüntüsü doğru sınıflanmıştır. 2 normal görüntü iskemi görüntüsü olarak, 6 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.978 ile en düşük değerdedir.

Çizelge 4.6. ResNet-50 ROC-AUC değerleri ve beş döngü ortalaması

| | Döngü | İskemi | Kanama | Normal |
|-----------------------------------|----------|---------------|--------------|--------------|
| ResNet-50 ROC-AUC değerleri | 1. Döngü | 0.989 | 0.988 | 0.968 |
| | 2. Döngü | 0.989 | 0.989 | 0.953 |
| | 3. Döngü | 0.989 | 0.987 | 0.973 |
| | 4. Döngü | 0.997 | 0.981 | 0.972 |
| | 5. Döngü | 0.995 | 0.983 | 0.978 |
| | Ortalama | 0.9918±±0.003 | 0.9856±0.003 | 0.9688±0.009 |

4.3. GoogleNet Sınıflandırma Sonuçları

5 kat çapraz geçişleme kullanılarak GoogleNet ile yapılan denemelerde ağ parametreleri Çizelge 4.7.'de ve her döngü için elde edilen sınıflandırma sonuçları Çizelge 4.8.'de verilmiştir.


Çizelge 4.7. GoogLeNet ağ eğitim özellikleri

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 6 |
| MiniBatchSize | 20 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |


Çizelge 4.8. GoogLeNet ağ performans değerleri

| Döngü | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Süre (sa:d:s) |
|----------|--------------|--------------|--------------|--------------|---------------|
| 1.Döngü | 0.9355 | 0.9344 | 0.9350 | 0.9333 | 00:07:14 |
| 2.Döngü | 0.8893 | 0.8663 | 0.8777 | 0.8833 | 00:07:11 |
| 3.Döngü | 0.9038 | 0.8970 | 0.9004 | 0.9000 | 00:07:11 |
| 4.Döngü | 0.8870 | 0.8960 | 0.8915 | 0.8889 | 00:07:18 |
| 5.Döngü | 0.9135 | 0.9068 | 0.9102 | 0.9111 | 00:07:16 |
| Ortalama | 0.9058±0.019 | 0.9001±0.024 | 0.9029±0.021 | 0.9033±0.019 | 00:07:14 |

Çizelge 4.8’de GoogLeNet ağ performans ortalama değeri verilmiştir. 0.90 üzeri değerler performansın yüksek olduğunu göstermektedir. Her döngünün süreleri 7 dakika civarındadır. Toplam süre 36 dakika 10 saniyedir. Bu süre zaman kaybı noktasında sınırın üstündedir.

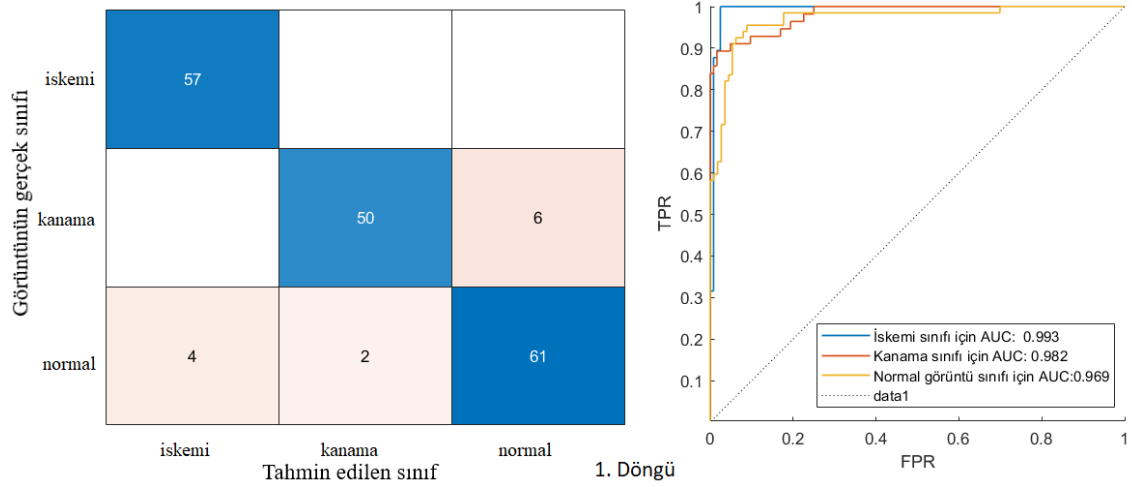
**Şekil 4.15.** GoogLeNet beş döngünün % doğruluk grafiği

Şekil 4.15’te, tüm döngülerde kısa sürede doğruluk oranı hızla yükselmiştir. İşlemin yarısına varmadan 100. İterasyondan sonra döngülerde yaklaşık %85 doğruluk oranına yaklaşmıştır. 150. İterasyondan sonra ağ, karlı hale gelmiştir. %90 doğruluk oranına ulaşılmıştır.



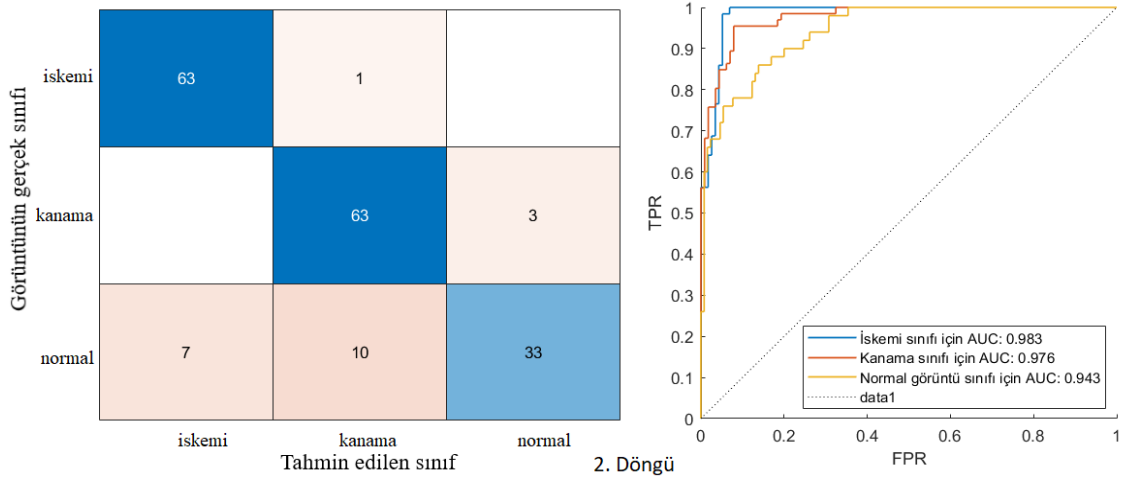
Şekil 4.16. GoogLeNet beş döngünün kayıp oranı grafiği

Şekil 4.16’da, tüm döngülerde tahmin edilen değer ile gerçek değer arasındaki hata değerinin kısa sürede azalması ile kayıp oranı hızla düşmüştür. İşlemin yarısına varmadan yaklaşık 0.4 kayıp oranına yaklaşılmıştır. 150. İterasyondan sonra ağ, karlı hale gelmiştir.



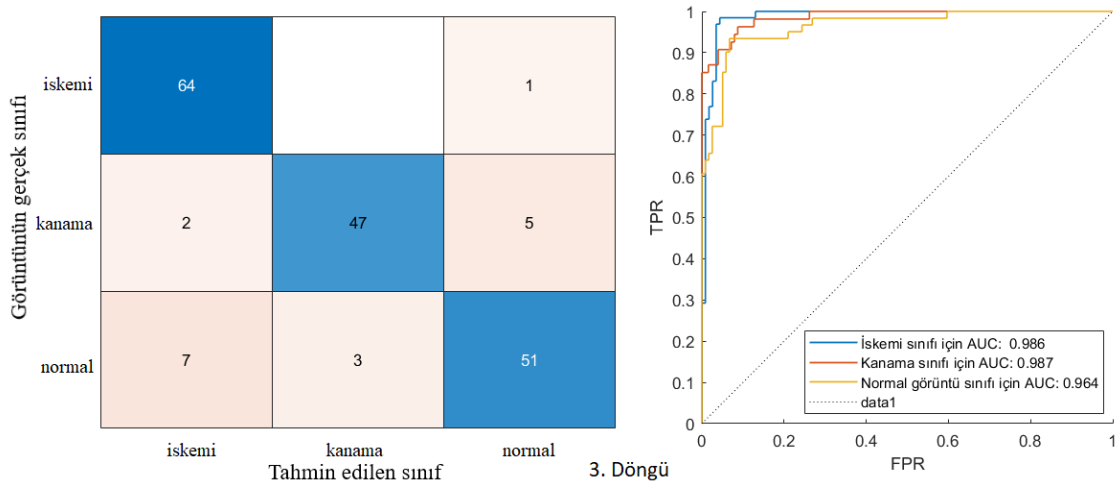
Şekil 4.17. GoogLeNet 1. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.17’de 57 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.993 ile en yüksek değerdedir. 50 kanama görüntüsü doğru sınıflanmıştır. 6 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.982’dir. 2. En iyi sınıflandırma değeridir. 61 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 2 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.969 ile en düşük değerdedir.



Şekil 4.18. GoogLeNet 2. Döngü karmaşıklık matrisi ve ROC grafiği


Şekil 4.18'de 63 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.983 ile en yüksek değerdedir. 63 kanama görüntüsü doğru sınıflanmıştır. 3 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.976'dır. 2. En iyi sınıflandırma değeridir. 33 normal beyin görüntüsü doğru sınıflanmıştır. 7 normal görüntü iskemi görüntüsü olarak, 10 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.943 ile en düşük değerdedir.



Şekil 4.19. GoogLeNet 3. Döngü karmaşıklık matrisi ve ROC grafiği


Şekil 4.19'da 64 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.986 ile en yüksek 2. değerdedir. 47 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 5 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.987'dir. 1. En iyi

sınıflandırma değeridir. 51 normal beyin görüntüsü doğru sınıflanmıştır. 7 normal görüntü iskemi görüntüsü olarak, 3 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.964 ile en düşük değerdedir.



Şekil 4.20. GoogLeNet 4. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.20’de 50 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.994 ile en yüksek değerdedir. 61 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 7 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.976’dir. 2. En iyi sınıflandırma değeridir. 49 normal beyin görüntüsü doğru sınıflanmıştır. 7 normal görüntü iskemi görüntüsü olarak, 4 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.965 ile en düşük değerdedir.



Şekil 4.21. GoogLeNet 5. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.21’de 64 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.994 ile en yüksek değerdedir. 45 kanama görüntüsü doğru sınıflanmıştır. 3 kanama görüntüsü iskemi olarak sınıflanmıştır. 6 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.976’dır. 2. En iyi sınıflandırma değeridir. 55 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 3 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.973 ile en düşük değerdedir.

Çizelge 4.9. GoogleNet ROC-AUC değerleri ve beş döngü ortalaması

| | Döngü | İskemi | Kanama | Normal |
|-----------------------------------|----------|------------|--------------|--------------|
| GoogleNet ROC-AUC değerleri | 1. Döngü | 0.993 | 0.982 | 0.969 |
| | 2. Döngü | 0.983 | 0.976 | 0.943 |
| | 3. Döngü | 0.986 | 0.987 | 0.964 |
| | 4. Döngü | 0.994 | 0.976 | 0.965 |
| | 5. Döngü | 0.994 | 0.976 | 0.973 |
| | Ortalama | 0.99±0.005 | 0.9794±0.004 | 0.9628±0.011 |

4.4.InceptionV3 sınıflandırma sonuçları

5 kat çapraz geçişleme kullanılarak InceptionV3 ile yapılan denemelerde ağ parametreleri Çizelge 4.10.’da ve her döngü için elde edilen sınıflandırma sonuçları Çizelge 4.11.’de verilmiştir.


Çizelge 4.10. InceptionV3 ağ eğitim özellikleri

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 6 |
| MiniBatchSize | 20 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |


Çizelge 4.11. InceptionV3 ağ performans değerleri

| Döngü | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Süre (sa:d:s) |
|----------|--------------|--------------|--------------|--------------|---------------|
| 1.Döngü | 0.8895 | 0.8918 | 0.8906 | 0.8889 | 00:09:56 |
| 2.Döngü | 0.8789 | 0.8744 | 0.8766 | 0.8833 | 00:11:09 |
| 3.Döngü | 0.8809 | 0.8733 | 0.8771 | 0.8778 | 00:11:28 |
| 4.Döngü | 0.8338 | 0.8468 | 0.8402 | 0.8333 | 00:11:59 |
| 5.Döngü | 0.9031 | 0.9042 | 0.9036 | 0.9056 | 00:12:06 |
| Ortalama | 0.8772±0.026 | 0.8781±0.021 | 0.8777±0.023 | 0.8778±0.026 | 00:11:20 |

Çizelge 4.11’de InceptionV3 ağ performans ortalama değerleri verilmiştir. 0.90 altı değerler performansın düşük olduğunu göstermektedir. Döngü süreleri 11 dakika civarındadır. Toplam süre 56 dakika 38 saniyedir. Bu süre zaman kaybı noktasında hasta hayatını tehlikeye atacak sürededir. Performans değerlerinin düşük olması ve işlem süresinin uzun olmasından dolayı teşhiste kullanılması uygun değildir.

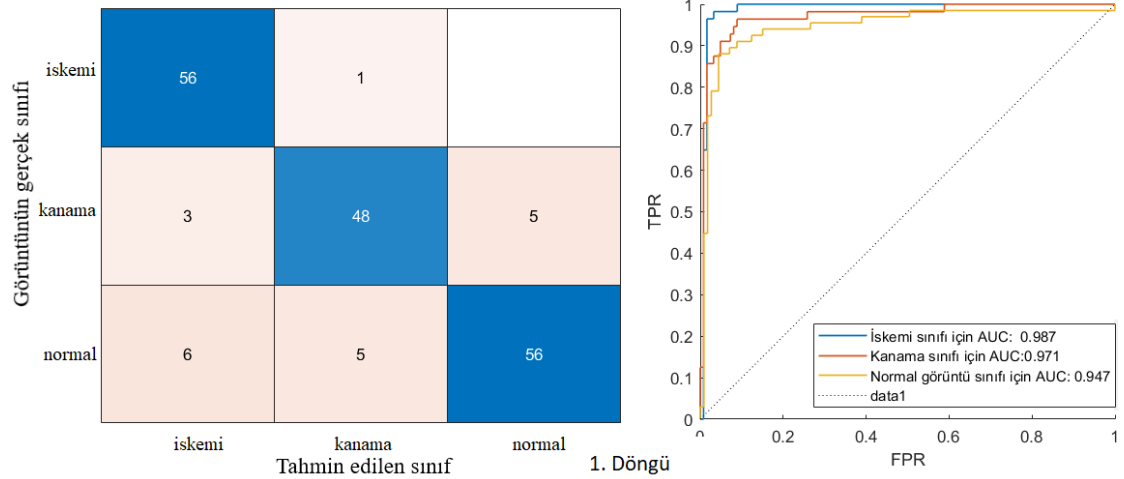
**Şekil 4.22.** InceptionV3 beş döngünün % doğruluk grafiği

Şekil 4.22’de, tüm döngülerde kısa sürede doğruluk oranı hızla yükselmiştir. İşlemin yarısına varmadan 200. İterasyondan sonra döngülerde yaklaşık %85 doğruluk oranına yaklaşılmıştır. 200. İterasyondan sonra ağ, karlı hale gelmiştir. %87 doğruluk oranına ulaşılmıştır.



Şekil 4.23. InceptionV3 beş döngünün kayıp oranı grafiği

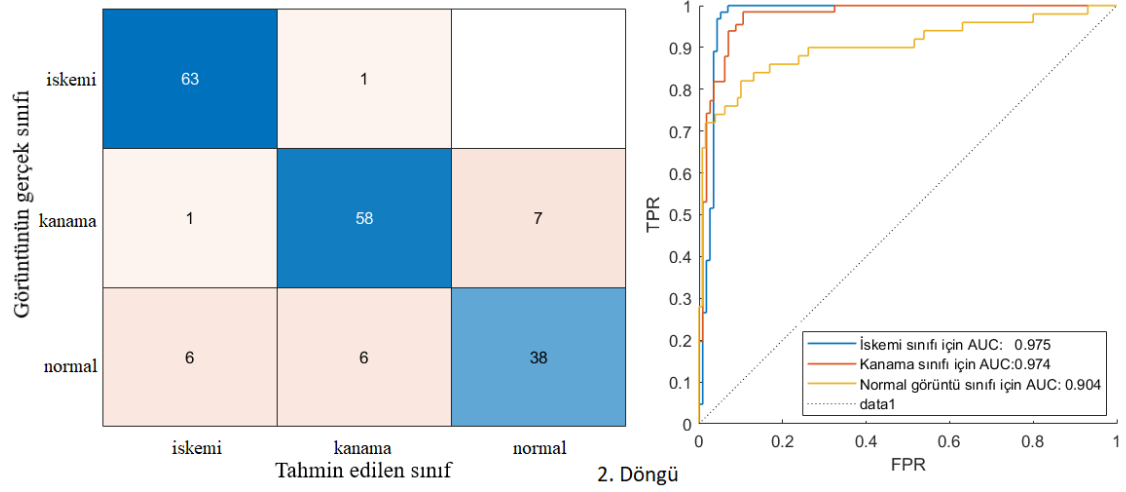
Şekil 4.23'te, tüm döngülerde tahmin edilen değer ile gerçek değer arasındaki hata değerinin azalması diğer döngülere göre daha uzun sürmüştür. Kayıp oranı yavaş düşmüştür. İşlem 180. İterasyonda yaklaşık 0.4 kayıp oranına yaklaşmıştır. 200. İterasyondan sonra ağ, karlı hale gelmiştir.



Şekil 4.24. InceptionV3 1. Döngü karmaşıklık matrisi ve ROC grafiği

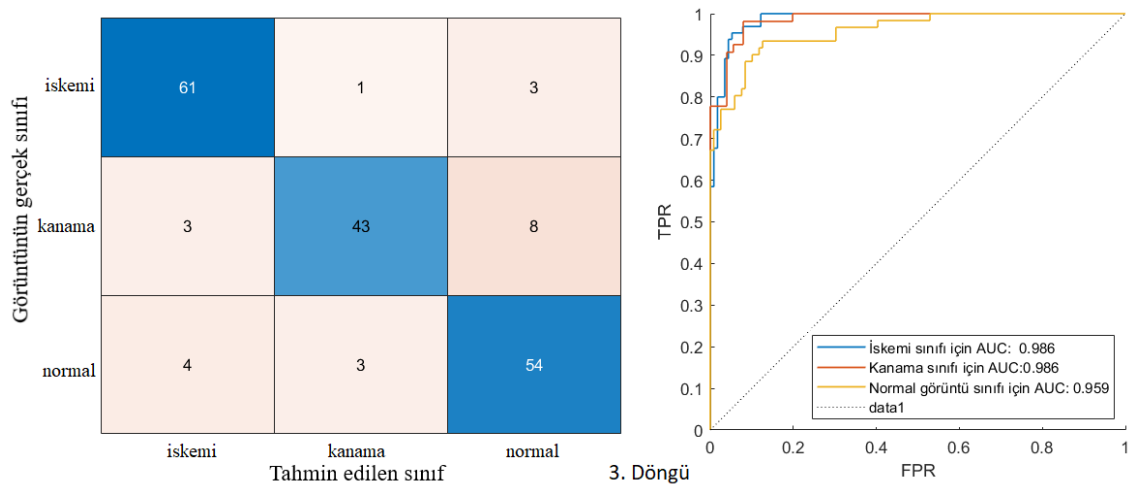
Şekil 4.24'te 56 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.9875 ile en yüksek değerdedir. 48 kanama görüntüsü doğru sınıflanmıştır. 3 kanama görüntüsü iskemi olarak sınıflanmıştır. 5 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.971'dir. 2. En iyi sınıflandırma değeridir. 56 normal beyin görüntüsü doğru sınıflanmıştır. 6 normal

görüntü is kemi görüntüsü olarak, 5 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.947 ile en düşük değerdedir.



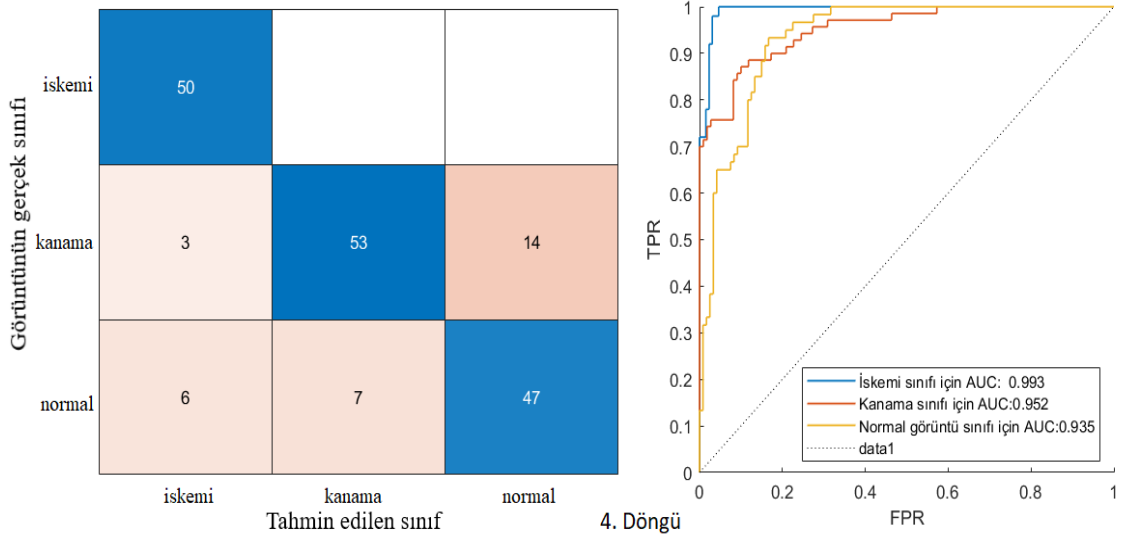
Şekil 4.25. InceptionV3 2. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.25'te 63 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.975 ile en yüksek değerdedir. 58 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır. 7 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.974'dür. 2. En iyi sınıflandırma değeridir. 38 normal beyin görüntüsü doğru sınıflanmıştır. 6 normal görüntü iskemi görüntüsü olarak, 6 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.904 ile en düşük değerdedir.



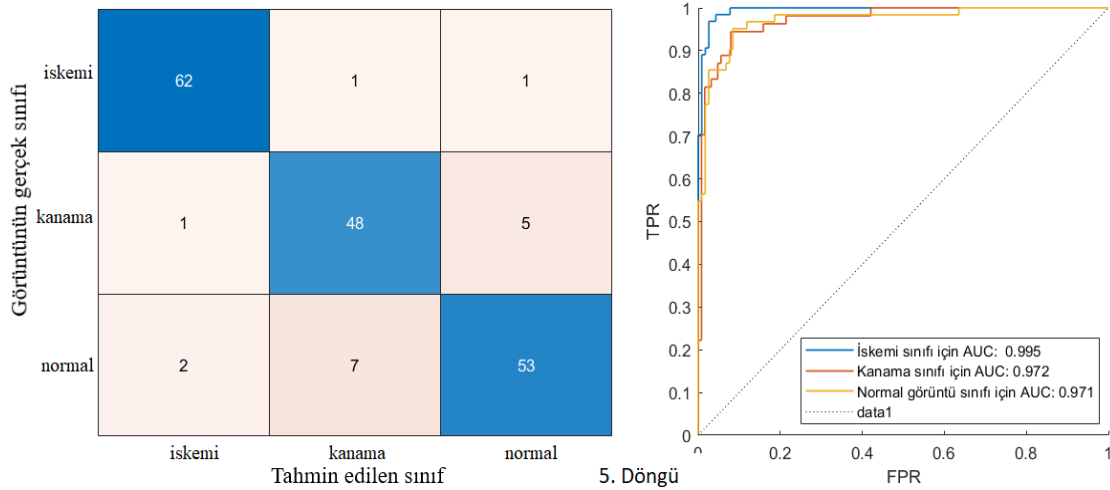
Şekil 4.26. InceptionV3 3. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.26'da 61 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. 3 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.986'dır. 43 kanama görüntüsü doğru sınıflanmıştır. 3 kanama görüntüsü iskemi olarak sınıflanmıştır. 8 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.986'dır. 54 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 3 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.959 ile en düşük değerdedir.



Şekil 4.27. InceptionV3 4. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.27'de 50 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.993 ile en yüksek değerdedir. 53 kanama görüntüsü doğru sınıflanmıştır. 3 kanama görüntüsü iskemi olarak sınıflanmıştır. 14 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.952'dir. 2. En iyi sınıflandırma değeridir. 47 normal beyin görüntüsü doğru sınıflanmıştır. 6 normal görüntü iskemi görüntüsü olarak, 7 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.935 ile en düşük değerdedir.



Şekil 4.28. InceptionV3 5. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.28’de 62 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.995 ile en yüksek değerdedir. 48 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır. 5 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.971’dir. 2. En iyi sınıflandırma değeridir. 53 normal beyin görüntüsü doğru sınıflanmıştır. 2 normal görüntü iskemi görüntüsü olarak, 7 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.971 ile en düşük değerdedir.

Çizelge 4.12. Inception V3 ROC-AUC değerleri ve beş döngü ortalaması

| | Döngü | İskemi | Kanama | Normal |
|--------------------------------------|----------|--------------|-------------|--------------|
| Inception V3 ROC-AUC değerleri | 1. Döngü | 0.987 | 0.971 | 0.947 |
| | 2. Döngü | 0.975 | 0.974 | 0.904 |
| | 3. Döngü | 0.986 | 0.986 | 0.959 |
| | 4. Döngü | 0.993 | 0.952 | 0.935 |
| | 5. Döngü | 0.995 | 0.972 | 0.971 |
| | Ortalama | 0.9872±0.007 | 0.971±0.012 | 0.9432±0.025 |

4.5.ShuffleNet sınıflandırma sonuçları

Beş kat çapraz geçişleme kullanılarak ShuffleNet ile yapılan denemelerde ağ parametreleri Çizelge 4.13.’te ve her döngü için elde edilen sınıflandırma sonuçları Çizelge 4.14.’te verilmiştir.


Çizelge 4.13. ShuffleNet ağ eğitim özellikleri

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 6 |
| MiniBatchSize | 20 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |

Çizelge 4.14. ShuffleNet ağ performans değerleri


| Döngü | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Süre (sa:d:s) |
|----------|--------------|--------------|--------------|--------------|---------------|
| 1.Döngü | 0.8963 | 0.8800 | 0.8881 | 0.8833 | 00:07:14 |
| 2.Döngü | 0.8832 | 0.8778 | 0.8805 | 0.8889 | 00:07:16 |
| 3.Döngü | 0.9044 | 0.9039 | 0.9041 | 0.9056 | 00:07:17 |
| 4.Döngü | 0.9013 | 0.9092 | 0.9052 | 0.9000 | 00:07:19 |
| 5.Döngü | 0.9233 | 0.9203 | 0.9218 | 0.9222 | 00:07:21 |
| Ortalama | 0.9017±0.014 | 0.8982±0.018 | 0.9000±0.016 | 0.9000±0.015 | 00:07:17 |

Çizelge 4.14'te ShuffleNet ağ performans ortalama değerleri verilmiştir. 0.90 civarı değerler performansın yüksek olduğunu göstermektedir. Her döngünün süreleri 7 dakika civarındadır. Toplam süre 36 dakika 27 saniyedir. Bu süre zaman kaybı noktasında sınırın üstündedir.



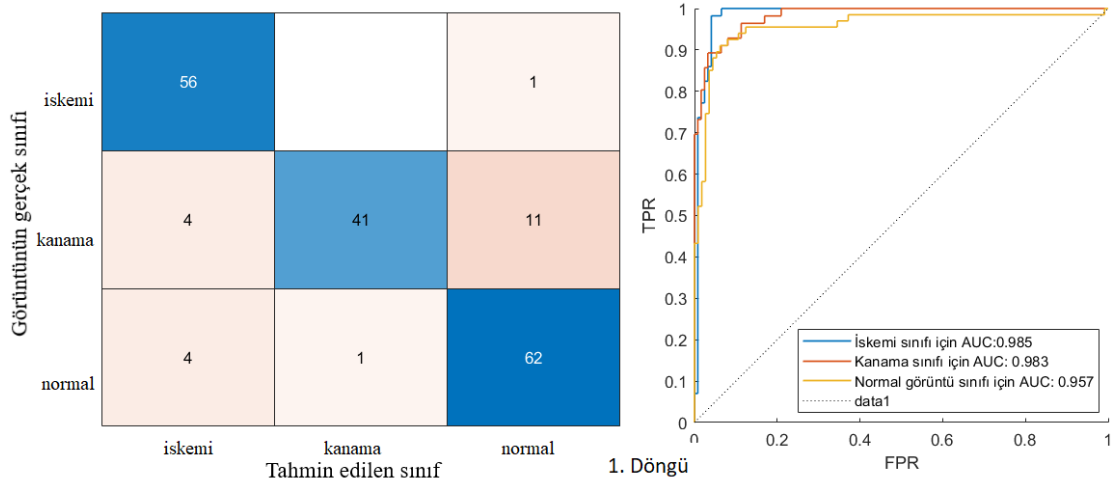
Şekil 4.29. ShuffleNet beş döngünün % doğruluk grafiği

Şekil 4.29’da, tüm döngülerde kısa sürede doğruluk oranı hızla yükselmiştir. İşlemin yarısına varmadan 100. İterasyondan sonra döngülerde yaklaşık %85 doğruluk oranına yaklaşılmıştır. 150. İterasyondan sonra ağ, karlı hale gelmiştir. %90 doğruluk oranına ulaşılmıştır.



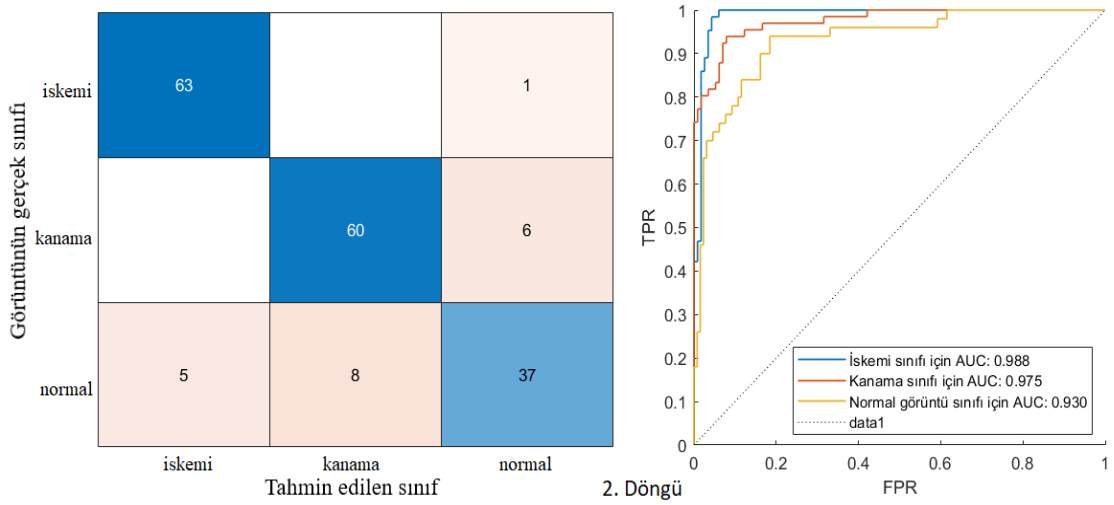
Şekil 4.30. ShuffleNet beş döngünün kayıp oranı grafiği

Şekil 4.30’da, tüm döngülerde tahmin edilen değer ile gerçek değer arasındaki hata değerinin kısa sürede azalması ile kayıp oranı hızla düşmüştür. İşlemin yarısına varmadan yaklaşık 0.5 kayıp oranına yaklaşılmıştır. 150. İterasyondan sonra ağ, karlı hale gelmiştir.




Şekil 4.31. ShuffleNet 1. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.31’de 56 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.985 ile en yüksek değerdedir. 41 kanama görüntüsü doğru sınıflanmıştır. 4 kanama görüntüsü iskemi olarak sınıflanmıştır. 11 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.983’tür. 2. En iyi sınıflandırma değeridir. 62 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 1 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.957 ile en düşük değerdedir.



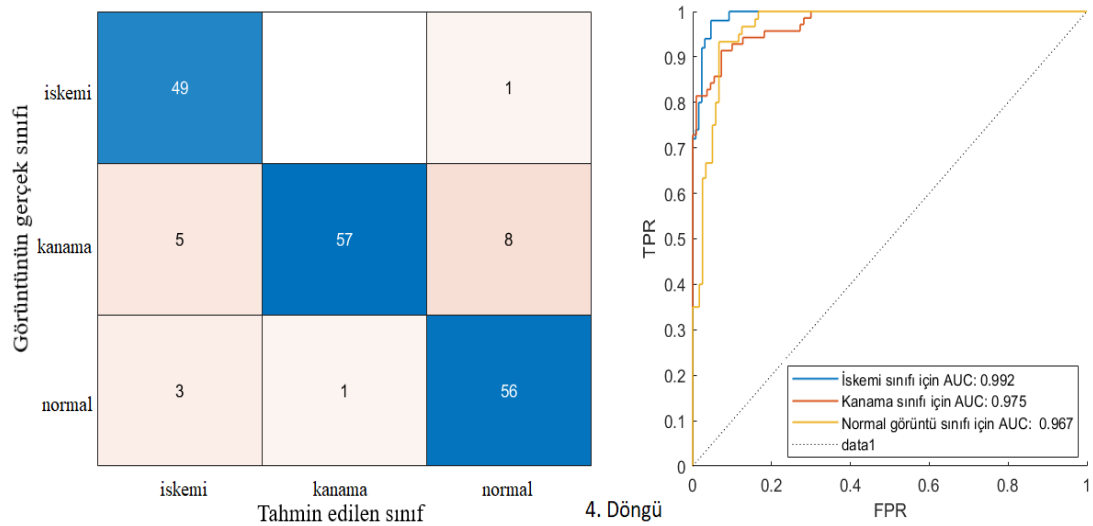
Şekil 4.32. ShuffleNet 2. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.32’de 63 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.988 ile en yüksek değerdedir. 60 kanama görüntüsü doğru sınıflanmıştır. 6 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.975’dir. 2. En iyi sınıflandırma değeridir. 37 normal beyin görüntüsü doğru sınıflanmıştır. 5 normal görüntü iskemi görüntüsü olarak, 8 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.930 ile en düşük değerdedir.



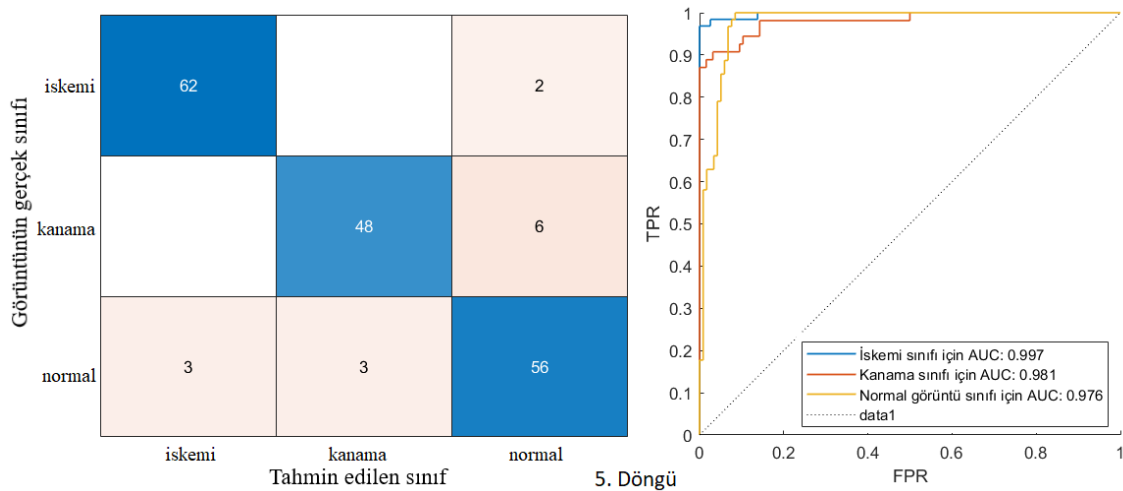
Şekil 4.33. ShuffleNet 3. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.33'te 64 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.979 ile en yüksek değerdedir. 49 kanama görüntüsü doğru sınıflanmıştır. 1 kanama görüntüsü iskemi olarak sınıflanmıştır. 4 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.978'dir. 2. En iyi sınıflandırma değeridir. 50 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 7 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.949 ile en düşük değerdedir.



Şekil 4.34. ShuffleNet 4. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.34'te 49 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.992 ile en yüksek değerdedir. 57 kanama görüntüsü doğru sınıflanmıştır. 5 kanama görüntüsü iskemi olarak sınıflanmıştır. 8 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.975'tir. 2. En iyi sınıflandırma değeridir. 56 normal beyin görüntüsü doğru sınıflanmıştır. 3 normal görüntü iskemi görüntüsü olarak, 1 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.967 ile en düşük değerdedir.



Şekil 4.35. ShuffleNet 5. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.35'te 62 iskemi görüntüsü doğru sınıflanmıştır. 2 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.997 ile en yüksek değerdedir. 48 kanama görüntüsü doğru sınıflanmıştır. 6 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.981'dir. 2. En iyi sınıflandırma değeridir. 56 normal beyin görüntüsü doğru sınıflanmıştır. 3 normal görüntü iskemi görüntüsü olarak, 3 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.976 ile en düşük değerdedir.

Çizelge 4.15. ShuffleNet ROC-AUC değerleri ve beş döngü ortalaması

| | Döngü | İskemi | Kanama | Normal |
|------------------------------------|----------|--------------|--------------|--------------|
| ShuffleNet ROC-AUC değerleri | 1. Döngü | 0.985 | 0.983 | 0.957 |
| | 2. Döngü | 0.988 | 0.975 | 0.93 |
| | 3. Döngü | 0.979 | 0.978 | 0.949 |
| | 4. Döngü | 0.992 | 0.975 | 0.967 |
| | 5. Döngü | 0.997 | 0.981 | 0.976 |
| | Ortalama | 0.9882±0.006 | 0.9784±0.003 | 0.9558±0.017 |

4.6.SqueezeNet sınıflandırma sonuçları

Beş kat çapraz geçerleme kullanılarak SqueezeNet ile yapılan denemelerde ağ parametreleri Çizelge 4.16.'da ve her döngü için elde edilen sınıflandırma sonuçları Çizelge 4.17.'de verilmiştir.


Çizelge 4.16. SqueezeNet ağ eğitim özellikleri

| İşlem | Özellik / Değeri |
|------------------------------|------------------|
| Momentum | 0.9 |
| InitialLearnRate | 1.00E-04 |
| LearnRateDropFactor | 0.2 |
| LearnRateDropPeriod | 5 |
| L2Regularization | 1.00E-04 |
| GradientThresholdMethod | l2norm |
| MaxEpochs | 6 |
| MiniBatchSize | 20 |
| Shuffle | every-epoch |
| ExecutionEnvironment | gpu |
| BatchNormalizationStatistics | population |

Çizelge 4.17. SqueezeNet ağ performans değerleri


| Döngü | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Süre (sa:d:s) |
|----------|--------------|--------------|--------------|--------------|---------------|
| 1.Döngü | 0.8462 | 0.8449 | 0.8455 | 0.8333 | 00:03:21 |
| 2.Döngü | 0.7905 | 0.7534 | 0.7715 | 0.7778 | 00:03:19 |
| 3.Döngü | 0.9026 | 0.8970 | 0.8998 | 0.9000 | 00:03:20 |
| 4.Döngü | 0.8353 | 0.8394 | 0.8373 | 0.8333 | 00:03:21 |
| 5.Döngü | 0.8721 | 0.8526 | 0.8622 | 0.8611 | 00:03:23 |
| Ortalama | 0.8493±0.041 | 0.8374±0.052 | 0.8433±0.046 | 0.8411±0.044 | 00:03:21 |

Çizelge 4.17'de SqueezeNet ağ performansortalama değerleri verilmiştir. 0.90 altı değerler performansın düşük olduğunu göstermektedir. Her döngünün süreleri 3.5 dakika civarındadır. Toplam süre 16 dakika 44 saniyedir. Bu süre zaman kaybı noktasında diğer ağlara göre en düşük süredir. Fakat performans değerlerinin 0.90 altı olması ağın teşhiste doktora yardımcı olamayacağını göstermektedir.



Şekil 4.36. SqueezeNet beş döngünün % doğruluk grafiği

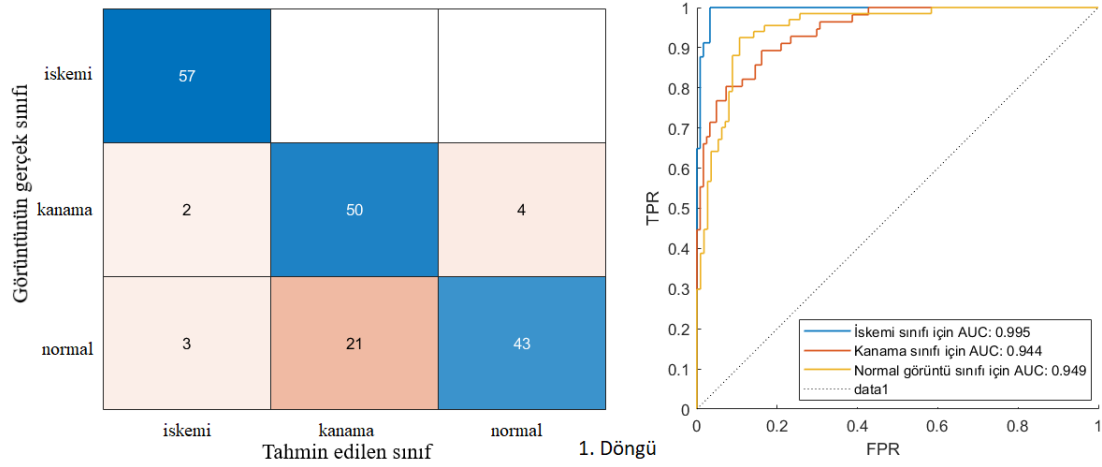
Şekil 4.36’da, tüm döngülerde kısa sürede doğruluk oranı hızla yükselmiştir. İşlemin yarısına varmadan 100. İterasyondan sonra döngülerde yaklaşık %75 doğruluk oranına yaklaşılmıştır. 150. İterasyondan sonra ağ, karlı hale gelmiştir. %84 doğruluk oranına ulaşılmıştır.



Şekil 4.37. SqueezeNet beş döngünün kayıp oranı grafiği

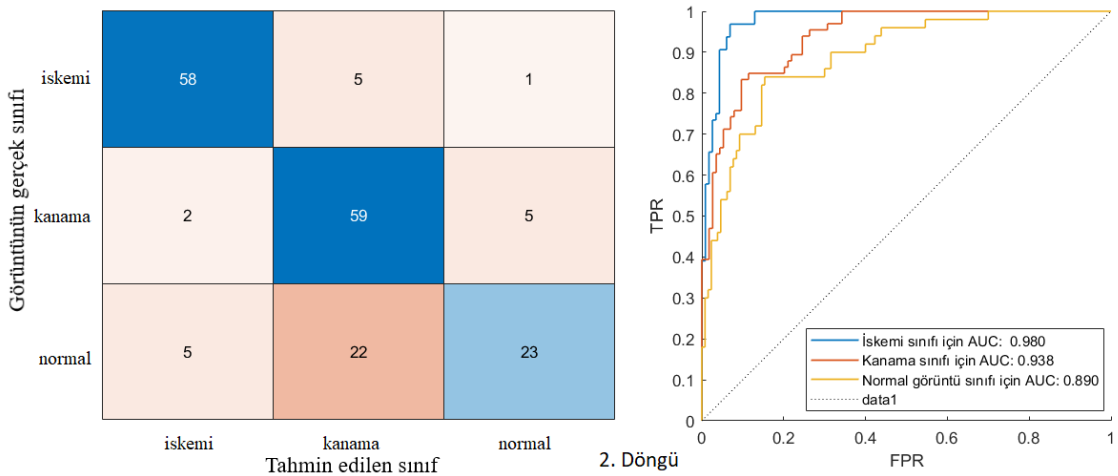
Şekil 4.37’de, tüm döngülerde tahmin edilen değer ile gerçek değer arasındaki hata değerinin kısa sürede azalması ile kayıp oranı hızla düşmüştür. İşlemin yarısına

varmadan yaklaşık 0.6 kayıp oranına yaklaşılmıştır. 150. İterasyondan sonra ağ, karlı hale gelmiştir.



Şekil 4.38. SqueezeNet 1. Döngü karmaşıklık matrisi ve ROC grafiği

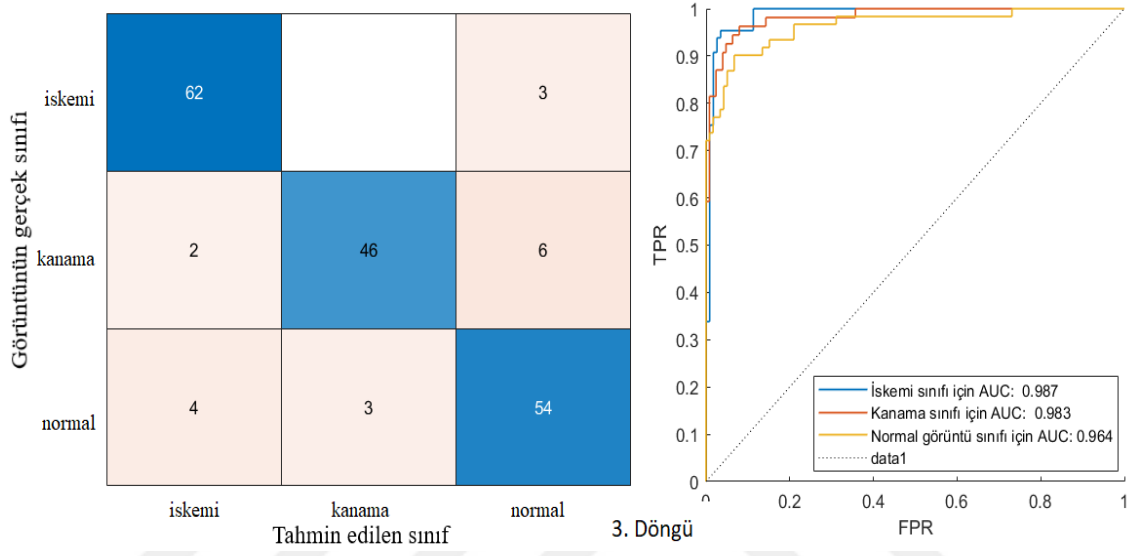
Şekil 4.38'de 57 iskemi görüntüsü doğru sınıflanmıştır. ROC-AUC değeri 0.995 ile en yüksek değerdedir. 50 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 4 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.944'tür. 43 normal beyin görüntüsü doğru sınıflanmıştır. 3 normal görüntü iskemi görüntüsü olarak, 21 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.949'dur.



Şekil 4.39. SqueezeNet 2. Döngü karmaşıklık matrisi ve ROC grafiği


Şekil 4.39'da 58 iskemi görüntüsü doğru sınıflanmıştır. 5 iskemi görüntüsü kanama olarak sınıflanmıştır. 1 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-

AUC değeri 0.980 ile en yüksek değerdedir. 59 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 5 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.938'dir. 2. En iyi sınıflandırma değeridir. 23 normal beyin görüntüsü doğru sınıflanmıştır. 5 normal görüntü iskemi görüntüsü olarak, 22 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.890 ile en düşük değerdedir.




Şekil 4.40. SqueezeNet 3. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.40'ta 62 iskemi görüntüsü doğru sınıflanmıştır. 3 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.987 ile en yüksek değerdedir. 46 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 6 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.983'tür. 2. En iyi sınıflandırma değeridir. 54 normal beyin görüntüsü doğru sınıflanmıştır. 4 normal görüntü iskemi görüntüsü olarak, 3 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.64 ile en düşük değerdedir.



Şekil 4.41. SqueezeNet 4. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.41’de 49 iskemi görüntüsü doğru sınıflanmıştır. 1 iskemi görüntüsü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.987 ile en yüksek değerdedir. 61 kanama görüntüsü doğru sınıflanmıştır. 2 kanama görüntüsü iskemi olarak sınıflanmıştır. 7 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.950’dir. 2. En iyi sınıflandırma değeridir. 40 normal beyin görüntüsü doğru sınıflanmıştır. 8 normal görüntü iskemi görüntüsü olarak, 12 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.933 ile en düşük değerdedir.



Şekil 4.42. SqueezeNet 5. Döngü karmaşıklık matrisi ve ROC grafiği

Şekil 4.42’de 61 iskemi görüntüsü doğru sınıflanmıştır. 3 iskemi görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.988 ile en yüksek değerdedir. 37

kanama görüntüsü doğru sınıflanmıştır. 4 kanama görüntüsü iskemi olarak sınıflanmıştır. 13 kanama görüntüsü normal olarak sınıflanmıştır. ROC-AUC değeri 0.929 ile en düşük değerdedir. 57 normal beyin görüntüsü doğru sınıflanmıştır. 2 normal görüntü iskemi görüntüsü olarak, 3 normal görüntü kanama olarak sınıflanmıştır. ROC-AUC değeri 0.943 ile 2. En iyi sınıflandırma değerindedir.

Çizelge 4.18. SqueezeNet ROC-AUC değerleri ve beş döngü ortalaması

| | Döngü | İskemi | Kanama | Normal |
|------------------------------------|----------|--------------|--------------|--------------|
| SqueezeNet ROC-AUC değerleri | 1. Döngü | 0.995 | 0.944 | 0.949 |
| | 2. Döngü | 0.98 | 0.938 | 0.89 |
| | 3. Döngü | 0.987 | 0.983 | 0.964 |
| | 4. Döngü | 0.987 | 0.95 | 0.933 |
| | 5. Döngü | 0.988 | 0.929 | 0.943 |
| | Ortalama | 0.9874±0.005 | 0.9488±0.020 | 0.9358±0.027 |

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Bu tez çalışmasında, BT görüntülerinde inmenin farklı derin öğrenme modelleri ile sınıflandırılması gerçekleştirilmiştir. Altı farklı derin öğrenme modelinin 5-kat çapraz geçişleme kullanılarak sınıflandırma performanslarının özeti ortalama ve standart sapma olarak Çizelge 5.1.'de verilmiştir.

Çizelge 5.1. Tüm ağların performans değerleri

| Ağ | Hassasiyet | Duyarlılık | F1 Puanı | Doğruluk | Toplam Süre (sa:d:s) |
|-------------|--------------|--------------|--------------|--------------|----------------------|
| AlexNet | 0.9086±0.02 | 0.9097±0.02 | 0.9091±0.02 | 0.9089±0.02 | 00:21:37 |
| ResNet-50 | 0.9092±0.01 | 0.9081±0.01 | 0.9086±0.01 | 0.9067±0.01 | 02:33:23 |
| GoogLeNet | 0.9058±0.019 | 0.9001±0.024 | 0.9029±0.021 | 0.9033±0.019 | 00:36:10 |
| InceptionV3 | 0.8772±0.026 | 0.8781±0.021 | 0.8777±0.023 | 0.8778±0.026 | 00:56:38 |
| ShuffleNet | 0.9017±0.014 | 0.8982±0.018 | 0.9000±0.016 | 0.9000±0.015 | 00:36:27 |
| SqueezeNet | 0.8493±0.041 | 0.8374±0.052 | 0.8433±0.046 | 0.8411±0.044 | 00:16:44 |

Çizelge 5.1.'de verildiği gibi AlexNet hem süre hem de doğruluk açısından en yüksek sonuçları vermiştir. Üç sınıflı çıkışların olduğu ağlarda ROC eğrisi ve AUC grafiklerinin yorumlanması için bir sınıfa karşılık diğer sınıflar değerlendirilmektedir. Bir sınıfa karşılık diğer sınıfların değerlendirilmesinde AUC performans kriterleri oldukça yüksek sonuçlar vermektedir. Çizelge 5.2.'de tüm ağların 5-kat çapraz geçişleme sonucu elde edilen AUC değerlerinin ortalaması ve standart sapması verilmiştir.

Çizelge 5.2. Tüm ağların ROC – AUC performans değerleri

| Ağ | İskemi | Kanama | Normal |
|-------------|--------------|--------------|--------------|
| AlexNet | 0.9920±0.005 | 0.9828±0.008 | 0.9686±0.012 |
| ResNet-50 | 0.9918±0.003 | 0.9856±0.003 | 0.9688±0.009 |
| GoogLeNet | 0.9900±0.005 | 0.9794±0.004 | 0.9628±0.011 |
| InceptionV3 | 0.9872±0.007 | 0.971±0.012 | 0.9432±0.025 |
| ShuffleNet | 0.9882±0.006 | 0.9784±0.003 | 0.9558±0.017 |
| SqueezeNet | 0.9874±0.005 | 0.9488±0.020 | 0.9358±0.027 |

Birden fazla performans özelliği birlikte değerlendirildiğinde daha nesnel bir sonuç elde edilmektedir. ROC grafiği duyarlılığın ve özgüllüğün etkili olduğu bir grafikdir. Doğruluk, F1 puanı ve ROC-AUC değerleri birlikte değerlendirildiğinde aşırı uç değerlerin daha az etkili olduğu performans değerleri elde edilmiş olur.

Çizelge 5.3'te tez çalışmasında gerçekleştirilen uygulamalar ve kaynak araştırması özeti karşılaştırmalı tablo olarak verilmiştir.

Çizelge 5.3. Makalelerin ve tez çalışmasının karşılaştırma çizelgesi

| Sıra No | Referans | İnme Türü | Görüntü | Görüntü Sayısı | Kullanılan Ağ | Doğrulama | Süre | Performans |
|---------|----------------------------|---------------------|-------------------|---|---|---|---|--|
| 1 | Phong ve ark., 2017 | Hemoraji | BT | 1700 | LeNet GoogLeNet Inception-ResNet | %80 eğitim, %20 test | 7.940 s, 879 s, 867 s | Doğruluk: 0.997 0.982 0.992 |
| 2 | Dourado Jr ve ark., 2019 | İskemi, Hemoraji | BT - DICOM | 140 normal, 140 iskemi, 140 hemoraji | MobilNet (Tüm sınıflandırmal arda en yüksek model) | %80 eğitim, %20 test | | Doğruluk: En düşük- Bayes sınıflandırıcı 0.915 En yüksek- kNN, MLP, Random Forest, SVM 1.000 |
| | | | BT – Gri skala | 140 normal, 140 iskemi, 140 hemoraji | NASNetLarge (Tüm sınıflandırmal arda en yüksek model) | %80 eğitim, %20 test | | Doğruluk: En düşük- Bayes sınıflandırıcı 0.7786 En yüksek- kNN, MLP, Random Forest, SVM 1.000 |
| 3 | Chin ve ark., 2017 | İskemi | BT | 256 | Çalışmaya özgü ESA | %50 eğitim, %50 test | | Doğruluk: 0.929 |
| 4 | Liu ve ark., 2018 | İskemi | MR | 212 | ResNet50 | 2-kat çapraz geçerleme | ~18 dk. | Dice: 0.654 |
| 5 | Chen ve ark., 2017 | İskemi | MR | 741 | EDDNet | MUSCLE Net 274 eğitim, 106 doğrulama, 361 test | Eğitim: 26.72 sa, Test: 0.9 s | Dice: 0.67 |
| 6 | Rajini ve Bhavani, 2013 | İskemi | BT | 15 iskemi vaka dosyası | k-ortalama kümeleme algoritması | SVM k-NN, ANN ve karar ağacı | | Doğruluk: 0.98 0.97 0.96 0.92 |
| 7 | Pereira ve ark., 2018 | İskemi, Hemoraji | BT | 100 normal, 100 iskemi, | Çalışmaya özgü ESA | %75 eğitim, %25 test | | Doğruluk: Hemoraji 0.975 iskemi 1.00 |

| | | | | | | | |
|----|----------------------------|---------------------|----|--|---|--|--------------------------------------|
| | | | | 100 hemoraji | | | normal beyin 0.991 |
| 8 | Clérigues ve ark., 2020 | İskemi | MR | SISS: 64 vaka dosyası SPES: 50 vaka dosyası | U-Net | SISS: 28 Eğitim dosyası, 36 test dosyası SPES: 30 Eğitim dosyası, 20 test dosyası | SISS Dice 0.59 SPES Dice 0.84 |
| 9 | Majumdar ve ark., 2018 | Hemoraji | BT | 4.300 | Çalışmaya özgü U-Net | 60 eğitim 5 doğrulama 69 test vakası | %81 duyarlılık %98 özgüllük |
| 10 | Gautam ve Raman, 2021 | İskemi, Hemoraji | BT | 31 normal, 25 iskemi, 18 hemoraji vakası | Çalışmaya özgü ESA | %80 eğitim, %20 test | Doğruluk: ~0.922 – 0.987 arası |
| 11 | Pan ve ark., 2021 | İskemi | BT | 116 iskemi 26 normal | ResNet | 58 iskemik vaka eğitim, 58 iskemik vaka test, 26 normal vaka test, | Doğruluk 0.759 |
| 12 | Lo ve ark., 2021 | İskemi | BT | 1254 | AlexNet Inception-v3 ResNet-101 | | Doğruluk: %90.49 - %95.49 |
| 13 | Watanabe ve ark., 2021 | Hemoraji | BT | 7914 | U-Net | %90 eğitim, %10 test | Doğruluk: Ortalama 0.897 |
| 14 | Gia ve ark., 2020 | Hemoraji | BT | 753107 | MobileNetV2 | 603032 eğitim 149771 doğrulama 304 test | 0.991 ROC-AUC |
| 15 | Hong ve ark., 2019 | Hemoraji | MR | 8574 örnek | ResNet-50 | 10-kat çapraz geçerleme | Doğruluk: Ortalama 0.9746 |
| 16 | Dawud ve ark., 2019 | Hemoraji | BT | 12635 | AlexNet-SVM | %70 eğitim, %30 test | Doğruluk- test: 93.48 |
| 17 | Jung ve Whangbo, 2020 | İskemi | BT | 356 vaka (16376 görüntü) | Çalışmaya özgü ESA | 13064 eğitim 3312 test | Doğruluk: ~ 0.6948 |
| 18 | Yu ve ark., 2020 | İskemi | MR | 182 vaka | U-Net | | 0.92 ROC-AUC |
| 19 | Zhang ve ark., 2020 | İskemi | MR | 4284 | Spesifik Algılama ve segmentasyon ağı (DSN) ve çok düzlemlili füzyon ağı (MPFN) | ISLES2015 SSIS DWI eğitim ve test veri seti | Dice: 0.622 |
| 20 | Zhang, Zhao, ve ark., 2018 | İskemi | MR | 242 | FCDenseNet | Eğitim 90, Doğrulama 62 Test 90 | Dice: 0.7913 |

| | | | | | | | |
|----|---------------------------|-------------------------|----|--------------------------------------|---|--------------------------|--|
| 21 | Perez Malla ve ark., 2019 | İskemi | MR | 75 vaka | DeepMedic v0.6.1 | Eğitim 43 vaka, Test 32 | Dice yaklaşık: 0.30 |
| 22 | Öman ve ark., 2019 | İskemi | BT | 60 vaka | DeepMedic | Eğitim 30 vaka, Test 30 | Dice: 0.61 |
| 23 | Shinohara ve ark., 2020 | İskemi | BT | 74 vaka | Xception | 35 iskemili 39 normal | Doğruluk: 0.865 |
| 24 | Soltanpour ve ark., 2019 | İskemi | BT | 156 vaka | U-Net (lojistik regresyon tabanlı) | 94 eğitim 62 test verisi | Dice en iyi modelde: 0.71 |
| 25 | Tez çalışması | İskemi, Hemoraji Normal | BT | 300 iskemili 300 Hemoraji 300 Normal | Alexnet ResNet-50 GoogLeNet InceptionV3 ShuffleNet SqueezeNet | 5 kat çapraz geçerleme | Doğruluk 0.9089 0.9067 0.9033 0.8778 0.9000 0.8411 |

Bu tez çalışması ve üç grubun aynı anda sınıflandırıldığı çalışmalar karşılaştırıldığında, bu tez çalışmasına en yakın olan çalışma Dourado Jr ve ark. (2019)'nın yapmış olduğu çalışmadır. Çalışmada DICOM formatındaki görüntülerde MobilNet daha başarılı olurken, gri skala görüntülerde NASNetLarge modeli daha başarılıdır. Ağların görüntü formatına göre başarısının değiştiği görülmektedir. Ön işleme yapılarak yüksek başarı elde edilmiştir. Bu sonuç farklı çalışmaların karşılaştırılmasında aynı görüntülerin ve aynı özellikte ön işlemlerin yapılarak karşılaştırılması gerektiğini ortaya çıkarmaktadır.

Pereira ve ark. (2018) kendi tasarladıkları az katman sayılı ağ ile başarı elde etmişlerdir. Görüntü sayısının daha fazla olduğu bir çalışmanın da yapılması gerektiğini önermişlerdir. Düşük görüntü sayısı ve başarıyı düşürecek görüntülerin çalışmalardan çıkarılması karşılaştırmanın nesnelliğini etkilemektedir.

Gautam ve Raman (2021) AlexNet ve ResNet'e karşı kendi tasarladıkları ESA'yı karşılaştırmışlardır. Verilerin %80 eğitim, % 20 test verisi olarak ayrıldığı uygulamada elde edilen sonuçlar iskemi ve kanama sınıfı olarak ele alınmış ve buna göre doğruluk hesaplamaları yapılmıştır. Bu hesaplama metodu daha yüksek değer vermektedir. Gerçek bir karşılaştırma yapılabilmesi için hesaplamaların 3 sınıf için yapılması gerekmektedir.

ROC-AUC değerlerinde %99,2'lik sonuçlara ulaşılması çalışmamızın diğer çalışmalardaki başarıları yakaladığı, temel algoritmalar ön işleme ve en temel performans değerleri ile yüksek sonuçlar alınabileceği gösterilmiştir. BT görüntüleri kullanılarak inmenin sınıflandırılması ve teşhisinde derin öğrenme modellerinin kullanımının bilgisayar destekli teşhise yardımcı olabileceği bu tezin önemli sonuçlarındandır.

5.2. Öneriler

Derin öğrenme modelleri son dönemlerde görüntü sınıflandırma, obje tanıma ve segmentasyon için kullanılan popüler bir yapay zekâ yöntemidir. Özellikle tıp alanında sinyal ve medikal görüntü kullanılarak gerçekleştirilen çalışmalar gün geçtikçe artmaktadır. Yeni teknolojilerin gelişmesi ile beraber tıpta hastalık teşhisi ve tahmini bilgisayar destekli yöntemlere kaymaktadır. Bundan dolayı kullanılan algoritmalar ve geliştirilen yöntemler ileri teknolojilerin gelişmesi için katkı sunacaktır.

Bu tez çalışmasında, BT görüntüleri kullanılarak 6 farklı derin öğrenme modeli üzerinde çalışma yapılmıştır. Farklı modellerle birlikte ağ yapısında, katmanlarda ve yöntemlerde yapılacak değişikliklerle başarı oranının yükselebileceği öngörülmektedir. Sınıflandırma konusunda başarılı sonuçlar alınsa da doğruluk oranlarının daha yüksek olması, hasta hayatını riske atmamak için gerekli olduğu düşünülmektedir. Kanama alanının segmentasyonunda sınır çizgilerinin belirlenmesi ve yoğunluk bilgilerinin kullanımı ile segmentasyon işlemi gerçekleştirilir. İskemik alan segmentasyonunda beyin diğer yarım küresine göre simetri, gri-beyaz madde çizgisinin kaybolması gibi konular incelendiğinden kanama segmentasyonunda kullanılan normal segmentasyon kurallarından daha karmaşık algoritmalar gerekmektedir. Segmentasyon konusunda yeni teknolojilerin ve yeni yöntemlerin gelişmesi ile sadece sınıflandırma konusunda değil, yeri ve boyutu konusunda da faydalı bilgiler sağlanacaktır. Ayrıca program boyutu ve mobil cihazlarda kullanılabilirlikleri gün geçtikçe önem kazanmaktadır. Bu sebeple mobil cihazlarda çalışacak ağların gelişmesi de inmenin tespitinde faydalı olacaktır. Sadece BT görüntüleri değil çalışmalarda farklı sekanslarda çekilen MR görüntüleri ve kontrastlı BT görüntüleri kullanılarak yapılacak araştırmalar çalışmaların gelişmesine katkı sağlayacaktır. Yarışmalarda kullanılan kaynak görüntülerde hasta isimleri ve diğer bilgiler ön işlemeden geçirilip çıkarılmaktadır. Hastanelerde doktorların kullanımına sunulan görüntülerde ise hastane adı, hasta adı soyadı, protokol numarası ve görüntünün teknik bilgileri mevcuttur. Bu alanlar programın doğruluğunu etkileyecektir. Sahada kullanıma sunulacak programlarda gerekli olmayan alanların ön işleme ile çıkartılması gerekmektedir. Yazılıma eklenilecek bir algoritma ile sadece kafatası içerisindeki bölgenin işleme alınması, performansı artıracaktır. Çalışmalarda veri toplama ve donanımsal konularda zorluklarla karşılaşılmaktadır. Kullanıcıların kullanımına açık medikal görüntü kaynakları çok kısıtlıdır. Özellikle iskemi ve kanama beyin görüntülerini bir arada bulmak mümkün değildir. Hastanelerden alınacak görüntüler için etik

kurullarının onayı gerekmektedir. Verilerin anonimleştirilerek arařtırmacılara kolaylık saęlanması, arařtırma sayısını daha da artıracaktır. Görüntü işleme için yüksek donanımsal özelliklere sahip bilgisayarlar veya iş istasyonları gerekmektedir. Çıkan her yeni program daha yüksek performans özellięi gerektirmektedir. Düşük performanslarda çalışabilecek programların geliştirilmesi yeni donanım gereksinimini azaltacaktır. Çalışmalarda Python dilinde açık kaynak kodlu Keras, TensorFlow kütüphaneleri ile hazırlanmış programlar da kullanılabilir. Açık kaynak kodlu programlar telif hakları açısından ve daha çok kişinin geliştirmeye katkı saęlaması sebebiyle tercih edilmektedir. Python dilinin esnek yapısı dięer platformlarla birlikte kullanımda kolaylık saęlayacaktır. Böylece üretilen sonuçlar doktorların kullanımında sabit bilgisayarlar yerine mobil cihazlar ile hareket anında ön teşhise yardımcı olacaktır.



6. KAYNAKLAR

- Acharya, U. R., Meiburger, K. M., Faust, O., Koh, J. E. W., Oh, S. L., Ciaccio, E. J., Subudhi, A., Jahmunah, V. ve Sabut, S. J. C. s. r., 2019, Automatic detection of ischemic stroke using higher order spectra features in brain MRI images, *Cognitive Systems Research* 58, 134-142.
- Anonim, 2020, *Derin Öğrenme*, [Online], https://tr.wikipedia.org/wiki/Derin_öğrenme, [Ziyaret Tarihi: 14 Haziran 2020]
- Chen, L., Bentley, P. ve Rueckert, D., 2017, Fully automatic acute ischemic lesion segmentation in DWI using convolutional neural networks, *NeuroImage: Clinical* 15, 633-643.
- Chin, C.-L., Lin, B.-J., Wu, G.-R., Weng, T.-C., Yang, C.-S., Su, R.-C. ve Pan, Y.-J., 2017, An automated early ischemic stroke detection system using CNN deep learning algorithm, *2017 IEEE 8th International Conference on Awareness Science and Technology (iCAST)*, Taiwan, 368-372
- Clèrigues, A., Valverde, S., Bernal, J., Freixenet, J., Oliver, A., Lladó, X. J. C. m. ve biomedicine, p. i., 2020, Acute and sub-acute stroke lesion segmentation from multimodal MRI, *Computer Methods and Programs in Biomedicine* 194, 105521.
- Çolak, T., Yencilek, H. İ., Kalaycıoğlu, O., Çelik, K. ve Tekten, B. Ö., 2020, Acil Serviste Akut İnme Tanısı Alan Hastaların Değerlendirilmesi: İki Yıllık Analiz, *Turk J Neurol* 26, 142-148.
- Dawud, A. M., Yurtkan, K. ve Oztoprak, H., 2019, Application of deep learning in neuroradiology: Brain haemorrhage classification using transfer learning, *Computational intelligence neuroscience* 2019.
- Dora, B., Önal, M., Arsava, E., Yılmaz, Ö., Kutluk, K. ve Uzuner, N., 2015, Tanı Yöntemleri: Türk Beyin Damar Hastalıkları Derneği İnme Tanı Ve Tedavi Kılavuzu-2015.
- Dourado Jr, C. M., da Silva, S. P. P., da Nobrega, R. V. M., Barros, A. C. d. S., Reboucas Filho, P. P. ve de Albuquerque, V. H. C. J. C. N., 2019, Deep learning IoT system for online stroke detection in skull computed tomography images, 152, 25-39.
- Emre, M. (2013), Nöroloji Temel Kitabı, *Güneş Tıp Kitapevleri*, Ankara, 669-792
- Gautam, A. ve Raman, B., 2021, Towards effective classification of brain hemorrhagic and ischemic stroke using CNN, *Biomedical Signal Processing Control* 63, 102178.
- Gia, K. L., Duong, H. N., Van, C. M., Thi, T. H. H., Nguyen, T. T., Thoai, N. ve Thi, T. T. T., 2020, A Computer-Aided Detection to Intracranial Hemorrhage by Using

Deep Learning: A Case Study, *Green Technology and Sustainable Development 2020*, Da Nang Eyaleti, Vietnam,

- Hakim, A., Reyes, M., Wiest, R., Lansberg, M. G., Christensen, S., Zaharchuk, G., Winzeck, S. ve Robben, D., 2018, *Ischemic Stroke Lesion Segmentation*, [Online], <http://www.isles-challenge.org/>, [Ziyaret Tarihi: 07.05.2020]
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778
- Hong, J., Cheng, H., Zhang, Y.-D. ve Liu, J., 2019, Detecting cerebral microbleeds with transfer learning, *Machine Vision Applications* 30, 1123-1133.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. ve Adam, H., 2017, Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv:04861*.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J. ve Keutzer, K., 2016, SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size, *arXiv preprint arXiv:07360*.
- İncir, R., 2020, Derin Öğrenme Yöntemi Kullanarak Web Tabanlı Kimlik Avı Saldırılarının Sınıflandırılması ,Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 58
- İnik, Ö. ve Ülker, E., 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi* 6, 85-104.
- Jung, S.-M. ve Whangbo, T.-K., 2020, A Deep Learning System for Diagnosing Ischemic Stroke by Applying Adaptive Transfer Learning, *Journal of Internet Technology* 21, 1957-1968.
- Karaali, F. Ç. ve Ülengin, F., 2008, Yapay Sinir Ağları ve bilişsel haritalar kullanılarak işsizlik oranı öngörü çalışması, *İtüdergisi/d* 7, 15-26.
- Karthik, R., Menaka, R., Johnson, A. ve Anand, S., 2020, Neuroimaging and deep learning for brain stroke detection-A review of recent advancements and future prospects, *Computer Methods and Programs in Biomedicine*, 105728.
- Kızrak, M. A., 2018, *Derine Daha Derine: Evrişimli Sinir Ağları*, [Online], Yıldız Technical University <https://medium.com/@ayyucekizrak/derine-daha-derine-evrişimli-sinir-ağları-2813a2c8b2a9>, [Ziyaret Tarihi: 15 Haziran 2020]
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, Montréal, 1097-1105

- Landgrebe, T. C. ve Duin, R. P., 2008, Efficient multiclass ROC approximation by decomposition via confusion matrix perturbation analysis, *IEEE transactions on pattern analysis machine intelligence* 30, 810-822.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE* 86, 2278-2324.
- Liu, Z., Cao, C., Ding, S., Liu, Z., Han, T. ve Liu, S. J. I. A., 2018, Towards clinical diagnosis: Automated stroke lesion segmentation on multi-spectral MR image using convolutional neural network, 6, 57006-57016.
- Lo, C.-M., Hung, P.-H. ve Lin, D.-T., 2021, Rapid Assessment of Acute Ischemic Stroke by Computed Tomography Using Deep Convolutional Neural Networks, *Journal of Digital Imaging*, 1-10.
- Majumdar, A., Brattain, L., Telfer, B., Farris, C. ve Scalera, J., 2018, Detecting intracranial hemorrhage with deep learning, *2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, 583-587
- McCulloch, W. S. ve Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics* 5, 115-133.
- MEB, 2011, *Radyoloji-Bilgisayarlı Tomografi Cihazları*, Milli Eğitim Bakanlığı, Ankara
- Narkhed, S., 2018, *Understanding AUC - ROC Curve*, [Online], <https://towardsdatascience.com/understanding-auc-roc-curve-68b2303cc9c5>, [Ziyaret Tarihi: 24.06.2021]
- Neuroimaging Informatics Tools and Resources Clearinghouse, N., 2020, *MRICro*, [Online], University of South Carolina <https://www.nitrc.org/projects/micro/>, [Ziyaret Tarihi: 20.10.2020]
- Öman, O., Mäkelä, T., Salli, E., Savolainen, S. ve Kangasniemi, M., 2019, 3D convolutional neural networks applied to CT angiography in the detection of acute ischemic stroke, *European radiology experimental* 3, 1-11.
- Pan, J., Wu, G., Yu, J., Geng, D., Zhang, J. ve Wang, Y., 2021, Detecting the Early Infarct Core on Non-Contrast CT Images with a Deep Learning Residual Network, *Journal of Stroke Cerebrovascular Diseases* 30, 105752.
- Pereira, D. R., Reboucas Filho, P. P., de Rosa, G. H., Papa, J. P. ve de Albuquerque, V. H. C., 2018, Stroke lesion detection using convolutional neural networks, *2018 International joint conference on neural networks (IJCNN)*, 1-6
- Perez Malla, C. U., Valdes Hernandez, M. d. C., Rachmadi, M. F. ve Komura, T., 2019, Evaluation of enhanced learning techniques for segmenting ischaemic stroke lesions in brain magnetic resonance perfusion images using a convolutional neural network scheme, *Frontiers in neuroinformatics* 13, 33.

- Phong, T. D., Duong, H. N., Nguyen, H. T., Trong, N. T., Nguyen, V. H., Van Hoa, T. ve Snasel, V., 2017, Brain hemorrhage diagnosis by using deep learning, *Proceedings of the 2017 International Conference on Machine Learning and Soft Computing*, 34-39
- Rajini, N. H. ve Bhavani, R. J. M., 2013, Computer aided detection of ischemic stroke using segmentation and texture features, *Measurement*, 46, 1865-1874.
- Röttger, D., 2014, Reconstruction and Visualization of Neuronal Pathways with Applications in Neuroscience, *Veröffentlicht als Dissertation der Universität Koblenz-Landau Naturwissenschaften*, Koblenz, 232
- RSNA, 2019, *Intracranial Hemorrhage Detection*, [Online], <https://www.kaggle.com/c/rsna-intracranial-hemorrhage-detection/rules>, [Ziyaret Tarihi: 30.10.2020]
- Sertkaya, M. E., 2018, Derin öğrenme tekniklerinin biyomedikal imgeler üzerine uygulamaları/Applications of deep learning techniques on biomedical images, , Yüksek Lisans Tezi, *Firat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 70
- Shinohara, Y., Takahashi, N., Lee, Y., Ohmura, T. ve Kinoshita, T., 2020, Development of a deep learning model to identify hyperdense MCA sign in patients with acute ischemic stroke, *Japanese journal of radiology* 38, 112-117.
- Soltanpour, M., Greiner, R., Boulanger, P. ve Buck, B., 2019, Ischemic Stroke Lesion Prediction in CT Perfusion Scans Using Multiple Parallel U-Nets Following by a Pixel-Level Classifier, *2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE)*, 957-963
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. J. T. j. o. m. l. r., 2014, Dropout: a simple way to prevent neural networks from overfitting, *The journal of machine learning research* 15, 1929-1958.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826
- Şahan, M., Satar, S., Koç, A. F. ve Sebe, A., 2010, İskemik İnme ve Akut Faz Reaktanları, *Arşiv Kaynak Tarama Dergisi* 19, 85-140.
- Watanabe, Y., Tanaka, T., Nishida, A., Takahashi, H., Fujiwara, M., Fujiwara, T., Arisawa, A., Yano, H., Tomiyama, N. ve Nakamura, H., 2021, Improvement of the diagnostic accuracy for intracranial haemorrhage using deep learning-based computer-assisted detection, *Neuroradiology* 63, 713-720.
- Yu, Y., Xie, Y., Thamm, T., Gong, E., Ouyang, J., Huang, C., Christensen, S., Marks, M. P., Lansberg, M. G. ve Albers, G. W., 2020, Use of deep learning to predict final ischemic stroke lesions from initial magnetic resonance imaging, *JAMA network open* 3, e200772-e200772.

- Zhang, L., Song, R., Wang, Y., Zhu, C., Liu, J., Yang, J. ve Liu, L., 2020, Ischemic Stroke Lesion Segmentation Using Multi-Plane Information Fusion, *IEEE Access* 8, 45715-45725.
- Zhang, R., Zhao, L., Lou, W., Abrigo, J. M., Mok, V. C., Chu, W. C., Wang, D. ve Shi, L., 2018, Automatic segmentation of acute ischemic stroke from DWI using 3-D fully convolutional DenseNets, *IEEE transactions on medical imaging* 37, 2149-2160.
- Zhang, X., Zhou, X., Lin, M. ve Sun, J., 2018, Shufflenet: An extremely efficient convolutional neural network for mobile devices, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 6848-6856



EKLER**EK-1** Kullanılan görüntülerin isimleri ve ayrıntıları.

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|----|---------------------------|----------|----------------|--------|
| 1 | SMIR.Brain.XX.O.CT.345562 | 3-8 | 6 | İskemi |
| 2 | SMIR.Brain.XX.O.CT.345569 | 1, 4-7 | 5 | İskemi |
| 3 | SMIR.Brain.XX.O.CT.345576 | 4-8 | 5 | İskemi |
| 4 | SMIR.Brain.XX.O.CT.345583 | 1-8 | 8 | İskemi |
| 5 | SMIR.Brain.XX.O.CT.345590 | 2-8 | 7 | İskemi |
| 6 | SMIR.Brain.XX.O.CT.345597 | 1-7 | 7 | İskemi |
| 7 | SMIR.Brain.XX.O.CT.345604 | 5-8 | 4 | İskemi |
| 8 | SMIR.Brain.XX.O.CT.345611 | 1-4 | 4 | İskemi |
| 9 | SMIR.Brain.XX.O.CT.345618 | 2-8 | 7 | İskemi |
| 10 | SMIR.Brain.XX.O.CT.345625 | 1-4 | 4 | İskemi |
| 11 | SMIR.Brain.XX.O.CT.345632 | 2-4 | 3 | İskemi |
| 12 | SMIR.Brain.XX.O.CT.345639 | 1-4 | 4 | İskemi |
| 13 | SMIR.Brain.XX.O.CT.345646 | 1-4 | 4 | İskemi |
| 14 | SMIR.Brain.XX.O.CT.345653 | 1-3 | 3 | İskemi |
| 15 | SMIR.Brain.XX.O.CT.345660 | 1-4 | 4 | İskemi |
| 16 | SMIR.Brain.XX.O.CT.345667 | 1-4 | 4 | İskemi |
| 17 | SMIR.Brain.XX.O.CT.345674 | 1-4 | 4 | İskemi |
| 18 | SMIR.Brain.XX.O.CT.339336 | 1,2 | 2 | İskemi |
| 19 | SMIR.Brain.XX.O.CT.339344 | 1,2 | 2 | İskemi |
| 20 | SMIR.Brain.XX.O.CT.345683 | 1,2 | 2 | İskemi |
| 21 | SMIR.Brain.XX.O.CT.345690 | 2 | 1 | İskemi |
| 22 | SMIR.Brain.XX.O.CT.345697 | 1 | 1 | İskemi |
| 23 | SMIR.Brain.XX.O.CT.345704 | 1,2 | 2 | İskemi |
| 24 | SMIR.Brain.XX.O.CT.345711 | 1-4 | 4 | İskemi |
| 25 | SMIR.Brain.XX.O.CT.345718 | 1-4 | 4 | İskemi |
| 26 | SMIR.Brain.XX.O.CT.345725 | 2-4 | 3 | İskemi |
| 27 | SMIR.Brain.XX.O.CT.345732 | 1-4 | 4 | İskemi |
| 28 | SMIR.Brain.XX.O.CT.345739 | 1-4 | 4 | İskemi |
| 29 | SMIR.Brain.XX.O.CT.345746 | 1-4 | 4 | İskemi |
| 30 | SMIR.Brain.XX.O.CT.345753 | 1-4 | 4 | İskemi |
| 31 | SMIR.Brain.XX.O.CT.345760 | 1-4 | 4 | İskemi |
| 32 | SMIR.Brain.XX.O.CT.345767 | 1-4 | 4 | İskemi |
| 33 | SMIR.Brain.XX.O.CT.345774 | 1-4 | 4 | İskemi |
| 34 | SMIR.Brain.XX.O.CT.345781 | 1,2 | 2 | İskemi |
| 35 | SMIR.Brain.XX.O.CT.345788 | 1,2 | 2 | İskemi |
| 36 | SMIR.Brain.XX.O.CT.345795 | 1,2 | 2 | İskemi |
| 37 | SMIR.Brain.XX.O.CT.345802 | 1,2 | 2 | İskemi |
| 38 | SMIR.Brain.XX.O.CT.345809 | 1,2 | 2 | İskemi |
| 39 | SMIR.Brain.XX.O.CT.345816 | 1,2 | 2 | İskemi |
| 40 | SMIR.Brain.XX.O.CT.345823 | 1,2 | 2 | İskemi |
| 41 | SMIR.Brain.XX.O.CT.345830 | 1,2 | 2 | İskemi |
| 42 | SMIR.Brain.XX.O.CT.345837 | 1,2 | 2 | İskemi |
| 43 | SMIR.Brain.XX.O.CT.345844 | 1,2 | 2 | İskemi |
| 44 | SMIR.Brain.XX.O.CT.345851 | 1,2 | 2 | İskemi |
| 45 | SMIR.Brain.XX.O.CT.345858 | 1,2 | 2 | İskemi |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|----|---------------------------|----------|----------------|--------|
| 46 | SMIR.Brain.XX.O.CT.345865 | 1,2 | 2 | İskemi |
| 47 | SMIR.Brain.XX.O.CT.345872 | 1,2 | 2 | İskemi |
| 48 | SMIR.Brain.XX.O.CT.345879 | 1,2 | 2 | İskemi |
| 49 | SMIR.Brain.XX.O.CT.345886 | 2 | 1 | İskemi |
| 50 | SMIR.Brain.XX.O.CT.345893 | 1,2 | 2 | İskemi |
| 51 | SMIR.Brain.XX.O.CT.345900 | 1 | 1 | İskemi |
| 52 | SMIR.Brain.XX.O.CT.345907 | 2 | 1 | İskemi |
| 53 | SMIR.Brain.XX.O.CT.345914 | 2 | 1 | İskemi |
| 54 | SMIR.Brain.XX.O.CT.345921 | 1 | 1 | İskemi |
| 55 | SMIR.Brain.XX.O.CT.345928 | 1,2 | 2 | İskemi |
| 56 | SMIR.Brain.XX.O.CT.345935 | 1,2 | 2 | İskemi |
| 57 | SMIR.Brain.XX.O.CT.345942 | 1,2 | 2 | İskemi |
| 58 | SMIR.Brain.XX.O.CT.345949 | 1,2 | 2 | İskemi |
| 59 | SMIR.Brain.XX.O.CT.345956 | 1,2 | 2 | İskemi |
| 60 | SMIR.Brain.XX.O.CT.345963 | 1,2 | 2 | İskemi |
| 61 | SMIR.Brain.XX.O.CT.345970 | 1,2 | 2 | İskemi |
| 62 | SMIR.Brain.XX.O.CT.345977 | 1,2 | 2 | İskemi |
| 63 | SMIR.Brain.XX.O.CT.345984 | 1,2 | 2 | İskemi |
| 64 | SMIR.Brain.XX.O.CT.345991 | 1,2 | 2 | İskemi |
| 65 | SMIR.Brain.XX.O.CT.345998 | 1,2 | 2 | İskemi |
| 66 | SMIR.Brain.XX.O.CT.346005 | 1,2 | 2 | İskemi |
| 67 | SMIR.Brain.XX.O.CT.346012 | 1 | 1 | İskemi |
| 68 | SMIR.Brain.XX.O.CT.346019 | 1,2 | 2 | İskemi |
| 69 | SMIR.Brain.XX.O.CT.346026 | 1,2 | 2 | İskemi |
| 70 | SMIR.Brain.XX.O.CT.346033 | 1,2 | 2 | İskemi |
| 71 | SMIR.Brain.XX.O.CT.346040 | 1,2 | 2 | İskemi |
| 72 | SMIR.Brain.XX.O.CT.346047 | 1,2 | 2 | İskemi |
| 73 | SMIR.Brain.XX.O.CT.346054 | 1,2 | 2 | İskemi |
| 74 | SMIR.Brain.XX.O.CT.346061 | 1,2 | 2 | İskemi |
| 75 | SMIR.Brain.XX.O.CT.346068 | 1,2 | 2 | İskemi |
| 76 | SMIR.Brain.XX.O.CT.346075 | 1,2 | 2 | İskemi |
| 77 | SMIR.Brain.XX.O.CT.346082 | 1,2 | 2 | İskemi |
| 78 | SMIR.Brain.XX.O.CT.346089 | 1,2 | 2 | İskemi |
| 79 | SMIR.Brain.XX.O.CT.346096 | 1,2 | 2 | İskemi |
| 80 | SMIR.Brain.XX.O.CT.346103 | 15-19 | 5 | İskemi |
| 81 | SMIR.Brain.XX.O.CT.346110 | 8-16 | 9 | İskemi |
| 82 | SMIR.Brain.XX.O.CT.346117 | 5-12 | 8 | İskemi |
| 83 | SMIR.Brain.XX.O.CT.346124 | 6-10 | 5 | İskemi |
| 84 | SMIR.Brain.XX.O.CT.346131 | 6-12 | 7 | İskemi |
| 85 | SMIR.Brain.XX.O.CT.346138 | 8-14 | 7 | İskemi |
| 86 | SMIR.Brain.XX.O.CT.346145 | 6-10 | 5 | İskemi |
| 87 | SMIR.Brain.XX.O.CT.346152 | 7-12 | 6 | İskemi |
| 88 | SMIR.Brain.XX.O.CT.346159 | 7-9 | 3 | İskemi |
| 89 | SMIR.Brain.XX.O.CT.346166 | 9,10 | 2 | İskemi |
| 90 | SMIR.Brain.XX.O.CT.346173 | 7-10 | 4 | İskemi |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|---------------------------|----------|----------------|--------|
| 91 | SMIR.Brain.XX.O.CT.346180 | 6-9 | 4 | İskemi |
| 92 | SMIR.Brain.XX.O.CT.346187 | 10-13 | 4 | İskemi |
| 93 | SMIR.Brain.XX.O.CT.346194 | 6-13 | 8 | İskemi |
| 94 | SMIR.Brain.XX.O.CT.346201 | 7-11 | 5 | İskemi |
| 95 | ID_001cc58e9 | 1 | 1 | Kanama |
| 96 | ID_00c3c70f5 | 1 | 1 | Kanama |
| 97 | ID_00f447a0b | 1 | 1 | Kanama |
| 98 | ID_013b88de5 | 1 | 1 | Kanama |
| 99 | ID_018a67ad0 | 1 | 1 | Kanama |
| 100 | ID_030919dbe | 1 | 1 | Kanama |
| 101 | ID_034a0e8ed | 1 | 1 | Kanama |
| 102 | ID_06a2ed50e | 1 | 1 | Kanama |
| 103 | ID_06b3df47b | 1 | 1 | Kanama |
| 104 | ID_081230aa4 | 1 | 1 | Kanama |
| 105 | ID_08d681167 | 1 | 1 | Kanama |
| 106 | ID_08e93673e | 1 | 1 | Kanama |
| 107 | ID_0a9690ee3 | 1 | 1 | Kanama |
| 108 | ID_0ac7a5626 | 1 | 1 | Kanama |
| 109 | ID_0b3bca360 | 1 | 1 | Kanama |
| 110 | ID_0c987aaf2 | 1 | 1 | Kanama |
| 111 | ID_0cdb51f49 | 1 | 1 | Kanama |
| 112 | ID_0cf33a9aa | 1 | 1 | Kanama |
| 113 | ID_0d311329a | 1 | 1 | Kanama |
| 114 | ID_0d614c369 | 1 | 1 | Kanama |
| 115 | ID_0e64882b5 | 1 | 1 | Kanama |
| 116 | ID_0f62cf181 | 1 | 1 | Kanama |
| 117 | ID_0fa244698 | 1 | 1 | Kanama |
| 118 | ID_12d42c619 | 1 | 1 | Kanama |
| 119 | ID_13e55ab18 | 1 | 1 | Kanama |
| 120 | ID_1400ffd7f | 1 | 1 | Kanama |
| 121 | ID_1437da989 | 1 | 1 | Kanama |
| 122 | ID_164ce6a4f | 1 | 1 | Kanama |
| 123 | ID_172bfa445 | 1 | 1 | Kanama |
| 124 | ID_174cdb0c6 | 1 | 1 | Kanama |
| 125 | ID_175b0158f | 1 | 1 | Kanama |
| 126 | ID_18b3a696f | 1 | 1 | Kanama |
| 127 | ID_18cdd767f | 1 | 1 | Kanama |
| 128 | ID_1a1d79524 | 1 | 1 | Kanama |
| 129 | ID_1a2e8cbe4 | 1 | 1 | Kanama |
| 130 | ID_1a36330ea | 1 | 1 | Kanama |
| 131 | ID_1a5befc2b | 1 | 1 | Kanama |
| 132 | ID_1a797250e | 1 | 1 | Kanama |
| 133 | ID_1b0abf0d7 | 1 | 1 | Kanama |
| 134 | ID_1b1f7ce70 | 1 | 1 | Kanama |
| 135 | ID_1b282a660 | 1 | 1 | Kanama |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 136 | ID_1b6c15c09 | 1 | 1 | Kanama |
| 137 | ID_1b7b5279b | 1 | 1 | Kanama |
| 138 | ID_1b842f388 | 1 | 1 | Kanama |
| 139 | ID_1bc7959ab | 1 | 1 | Kanama |
| 140 | ID_1c3dc8657 | 1 | 1 | Kanama |
| 141 | ID_1c5682d6c | 1 | 1 | Kanama |
| 142 | ID_1e3c72d19 | 1 | 1 | Kanama |
| 143 | ID_1e480e99e | 1 | 1 | Kanama |
| 144 | ID_1f114f680 | 1 | 1 | Kanama |
| 145 | ID_1f948563a | 1 | 1 | Kanama |
| 146 | ID_1facf7710 | 1 | 1 | Kanama |
| 147 | ID_1fc01b3bf | 1 | 1 | Kanama |
| 148 | ID_1fd17bbc9 | 1 | 1 | Kanama |
| 149 | ID_1fe44ac4e | 1 | 1 | Kanama |
| 150 | ID_1faceb3a | 1 | 1 | Kanama |
| 151 | ID_20d508c34 | 1 | 1 | Kanama |
| 152 | ID_20d8805a7 | 1 | 1 | Kanama |
| 153 | ID_2535be5f6 | 1 | 1 | Kanama |
| 154 | ID_2602d7709 | 1 | 1 | Kanama |
| 155 | ID_2614bcb52 | 1 | 1 | Kanama |
| 156 | ID_262127fc2 | 1 | 1 | Kanama |
| 157 | ID_26ae1841e | 1 | 1 | Kanama |
| 158 | ID_26e7b9063 | 1 | 1 | Kanama |
| 159 | ID_27eacc5e0 | 1 | 1 | Kanama |
| 160 | ID_2a3ab07a0 | 1 | 1 | Kanama |
| 161 | ID_2a4e70d18 | 1 | 1 | Kanama |
| 162 | ID_2aa703d66 | 1 | 1 | Kanama |
| 163 | ID_2b4804310 | 1 | 1 | Kanama |
| 164 | ID_2c9bdfbd1 | 1 | 1 | Kanama |
| 165 | ID_2d1e91b00 | 1 | 1 | Kanama |
| 166 | ID_2d20d1449 | 1 | 1 | Kanama |
| 167 | ID_2d8f02e15 | 1 | 1 | Kanama |
| 168 | ID_2d9cd1a69 | 1 | 1 | Kanama |
| 169 | ID_2e5ea423c | 1 | 1 | Kanama |
| 170 | ID_2e6814c94 | 1 | 1 | Kanama |
| 171 | ID_2ea97cf89 | 1 | 1 | Kanama |
| 172 | ID_2f0934507 | 1 | 1 | Kanama |
| 173 | ID_32038b87a | 1 | 1 | Kanama |
| 174 | ID_33aa5654c | 1 | 1 | Kanama |
| 175 | ID_363cc676e | 1 | 1 | Kanama |
| 176 | ID_365d005d4 | 1 | 1 | Kanama |
| 177 | ID_372d07798 | 1 | 1 | Kanama |
| 178 | ID_375b72a60 | 1 | 1 | Kanama |
| 179 | ID_379d24de8 | 1 | 1 | Kanama |
| 180 | ID_37e1ee5d1 | 1 | 1 | Kanama |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 181 | ID_37e2d7ebb | 1 | 1 | Kanama |
| 182 | ID_391e88358 | 1 | 1 | Kanama |
| 183 | ID_392f10297 | 1 | 1 | Kanama |
| 184 | ID_39468e20a | 1 | 1 | Kanama |
| 185 | ID_3953f1438 | 1 | 1 | Kanama |
| 186 | ID_39bbebc65 | 1 | 1 | Kanama |
| 187 | ID_3c02bb5d9 | 1 | 1 | Kanama |
| 188 | ID_3c300c405 | 1 | 1 | Kanama |
| 189 | ID_3c5140061 | 1 | 1 | Kanama |
| 190 | ID_3c73219fd | 1 | 1 | Kanama |
| 191 | ID_3cd798626 | 1 | 1 | Kanama |
| 192 | ID_3e9f3c8d5 | 1 | 1 | Kanama |
| 193 | ID_3eac0c5f1 | 1 | 1 | Kanama |
| 194 | ID_3edb0b14e | 1 | 1 | Kanama |
| 195 | ID_3fbc29770 | 1 | 1 | Kanama |
| 196 | ID_3fdd225bb | 1 | 1 | Kanama |
| 197 | ID_406131a15 | 1 | 1 | Kanama |
| 198 | ID_4110920c1 | 1 | 1 | Kanama |
| 199 | ID_41e272212 | 1 | 1 | Kanama |
| 200 | ID_4309c9e27 | 1 | 1 | Kanama |
| 201 | ID_437c28cb2 | 1 | 1 | Kanama |
| 202 | ID_44c9165cd | 1 | 1 | Kanama |
| 203 | ID_4598fa77a | 1 | 1 | Kanama |
| 204 | ID_45be4ec40 | 1 | 1 | Kanama |
| 205 | ID_45fb11dc4 | 1 | 1 | Kanama |
| 206 | ID_46431bc08 | 1 | 1 | Kanama |
| 207 | ID_479ea5fb8 | 1 | 1 | Kanama |
| 208 | ID_47bc40359 | 1 | 1 | Kanama |
| 209 | ID_4847cc53a | 1 | 1 | Kanama |
| 210 | ID_48d6430cf | 1 | 1 | Kanama |
| 211 | ID_4b8e92b27 | 1 | 1 | Kanama |
| 212 | ID_4c12ce93c | 1 | 1 | Kanama |
| 213 | ID_4c1ebc1d0 | 1 | 1 | Kanama |
| 214 | ID_4cf37691b | 1 | 1 | Kanama |
| 215 | ID_4d5ae5b60 | 1 | 1 | Kanama |
| 216 | ID_4e943c21c | 1 | 1 | Kanama |
| 217 | ID_4fa0e5951 | 1 | 1 | Kanama |
| 218 | ID_50b2f1c22 | 1 | 1 | Kanama |
| 219 | ID_50d17b2e5 | 1 | 1 | Kanama |
| 220 | ID_512fd908b | 1 | 1 | Kanama |
| 221 | ID_515b6d6f8 | 1 | 1 | Kanama |
| 222 | ID_518cce5aa | 1 | 1 | Kanama |
| 223 | ID_525c57473 | 1 | 1 | Kanama |
| 224 | ID_5351cb209 | 1 | 1 | Kanama |
| 225 | ID_5562db6a6 | 1 | 1 | Kanama |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 226 | ID_55a8fee48 | 1 | 1 | Kanama |
| 227 | ID_5757b6b01 | 1 | 1 | Kanama |
| 228 | ID_5781c395f | 1 | 1 | Kanama |
| 229 | ID_58b0404ee | 1 | 1 | Kanama |
| 230 | ID_58b22e6c8 | 1 | 1 | Kanama |
| 231 | ID_59386e0e5 | 1 | 1 | Kanama |
| 232 | ID_5a1aac8cb | 1 | 1 | Kanama |
| 233 | ID_5a7bbfa5c | 1 | 1 | Kanama |
| 234 | ID_5c25885d4 | 1 | 1 | Kanama |
| 235 | ID_5c3ae9189 | 1 | 1 | Kanama |
| 236 | ID_5c4337723 | 1 | 1 | Kanama |
| 237 | ID_5cabd9ce5 | 1 | 1 | Kanama |
| 238 | ID_5cbc6f5eb | 1 | 1 | Kanama |
| 239 | ID_5d1f38e31 | 1 | 1 | Kanama |
| 240 | ID_5d58a710e | 1 | 1 | Kanama |
| 241 | ID_5e56aaa09 | 1 | 1 | Kanama |
| 242 | ID_5e962bf59 | 1 | 1 | Kanama |
| 243 | ID_60f89ded6 | 1 | 1 | Kanama |
| 244 | ID_617e8c0e5 | 1 | 1 | Kanama |
| 245 | ID_61ce34822 | 1 | 1 | Kanama |
| 246 | ID_62a0e24e5 | 1 | 1 | Kanama |
| 247 | ID_62fddf5c4 | 1 | 1 | Kanama |
| 248 | ID_6367fa0c7 | 1 | 1 | Kanama |
| 249 | ID_637b527a5 | 1 | 1 | Kanama |
| 250 | ID_64ffe8f4 | 1 | 1 | Kanama |
| 251 | ID_65a0c3723 | 1 | 1 | Kanama |
| 252 | ID_65b89c3d0 | 1 | 1 | Kanama |
| 253 | ID_662b3768b | 1 | 1 | Kanama |
| 254 | ID_6af0c3670 | 1 | 1 | Kanama |
| 255 | ID_6b0d1a110 | 1 | 1 | Kanama |
| 256 | ID_6b3399dfc | 1 | 1 | Kanama |
| 257 | ID_6be0c33c9 | 1 | 1 | Kanama |
| 258 | ID_6ca119d77 | 1 | 1 | Kanama |
| 259 | ID_6d3b7b0f5 | 1 | 1 | Kanama |
| 260 | ID_6d728251b | 1 | 1 | Kanama |
| 261 | ID_6dc5c9e30 | 1 | 1 | Kanama |
| 262 | ID_6e0229fdb | 1 | 1 | Kanama |
| 263 | ID_6f0f191dc | 1 | 1 | Kanama |
| 264 | ID_6f68b4e81 | 1 | 1 | Kanama |
| 265 | ID_73981a3c6 | 1 | 1 | Kanama |
| 266 | ID_750a6a27e | 1 | 1 | Kanama |
| 267 | ID_760cd6a38 | 1 | 1 | Kanama |
| 268 | ID_761b1db13 | 1 | 1 | Kanama |
| 269 | ID_76828c3a7 | 1 | 1 | Kanama |
| 270 | ID_77a3fa27f | 1 | 1 | Kanama |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 271 | ID_79a673dbf | 1 | 1 | Kanama |
| 272 | ID_7c71b48a3 | 1 | 1 | Kanama |
| 273 | ID_7cf5202cd | 1 | 1 | Kanama |
| 274 | ID_7e1ac0511 | 1 | 1 | Kanama |
| 275 | ID_7e22f8840 | 1 | 1 | Kanama |
| 276 | ID_7e6e4ad93 | 1 | 1 | Kanama |
| 277 | ID_7e84649c5 | 1 | 1 | Kanama |
| 278 | ID_7f23a76ea | 1 | 1 | Kanama |
| 279 | ID_7fda34bf1 | 1 | 1 | Kanama |
| 280 | ID_8077edd49 | 1 | 1 | Kanama |
| 281 | ID_80bc097a7 | 1 | 1 | Kanama |
| 282 | ID_820ceed0b | 1 | 1 | Kanama |
| 283 | ID_82b188665 | 1 | 1 | Kanama |
| 284 | ID_82c0c6782 | 1 | 1 | Kanama |
| 285 | ID_83e8b6548 | 1 | 1 | Kanama |
| 286 | ID_846efc518 | 1 | 1 | Kanama |
| 287 | ID_847e4cd87 | 1 | 1 | Kanama |
| 288 | ID_854e6d869 | 1 | 1 | Kanama |
| 289 | ID_857c5f79b | 1 | 1 | Kanama |
| 290 | ID_85df416b6 | 1 | 1 | Kanama |
| 291 | ID_88df80989 | 1 | 1 | Kanama |
| 292 | ID_88f97d7d3 | 1 | 1 | Kanama |
| 293 | ID_8978bc1fc | 1 | 1 | Kanama |
| 294 | ID_89ad2ddb1 | 1 | 1 | Kanama |
| 295 | ID_8a1d54b28 | 1 | 1 | Kanama |
| 296 | ID_8a32a4511 | 1 | 1 | Kanama |
| 297 | ID_8a34d91fa | 1 | 1 | Kanama |
| 298 | ID_8a8da7d04 | 1 | 1 | Kanama |
| 299 | ID_8bc3d6e20 | 1 | 1 | Kanama |
| 300 | ID_8c9b32bd9 | 1 | 1 | Kanama |
| 301 | ID_8cda4ee10 | 1 | 1 | Kanama |
| 302 | ID_8ce84e8e5 | 1 | 1 | Kanama |
| 303 | ID_8d32d3ec3 | 1 | 1 | Kanama |
| 304 | ID_8de635b2d | 1 | 1 | Kanama |
| 305 | ID_8e5a8e582 | 1 | 1 | Kanama |
| 306 | ID_8eca94a33 | 1 | 1 | Kanama |
| 307 | ID_8ee6e71fc | 1 | 1 | Kanama |
| 308 | ID_8f65ca419 | 1 | 1 | Kanama |
| 309 | ID_902f79eb1 | 1 | 1 | Kanama |
| 310 | ID_90bce6668 | 1 | 1 | Kanama |
| 311 | ID_9109e2cfc | 1 | 1 | Kanama |
| 312 | ID_911d09f0c | 1 | 1 | Kanama |
| 313 | ID_91b7abc96 | 1 | 1 | Kanama |
| 314 | ID_92a3f1dc6 | 1 | 1 | Kanama |
| 315 | ID_92b068ed8 | 1 | 1 | Kanama |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 316 | ID_92de8633d | 1 | 1 | Kanama |
| 317 | ID_92fd8fc2a | 1 | 1 | Kanama |
| 318 | ID_94227a5e7 | 1 | 1 | Kanama |
| 319 | ID_94d2fab71 | 1 | 1 | Kanama |
| 320 | ID_96c54fe90 | 1 | 1 | Kanama |
| 321 | ID_9aa2ec048 | 1 | 1 | Kanama |
| 322 | ID_9aa74bb15 | 1 | 1 | Kanama |
| 323 | ID_9aa8c685a | 1 | 1 | Kanama |
| 324 | ID_9d8eb50ee | 1 | 1 | Kanama |
| 325 | ID_9f4536092 | 1 | 1 | Kanama |
| 326 | ID_9f6e4a22b | 1 | 1 | Kanama |
| 327 | ID_9fc281c7c | 1 | 1 | Kanama |
| 328 | ID_a3491018c | 1 | 1 | Kanama |
| 329 | ID_a440ef63d | 1 | 1 | Kanama |
| 330 | ID_a53b1e041 | 1 | 1 | Kanama |
| 331 | ID_a57f5a97 | 1 | 1 | Kanama |
| 332 | ID_a64f7ad14 | 1 | 1 | Kanama |
| 333 | ID_a67b9a79e | 1 | 1 | Kanama |
| 334 | ID_a710c2e04 | 1 | 1 | Kanama |
| 335 | ID_a843d05ea | 1 | 1 | Kanama |
| 336 | ID_a874ec2b5 | 1 | 1 | Kanama |
| 337 | ID_a9880e187 | 1 | 1 | Kanama |
| 338 | ID_acc6ecf65 | 1 | 1 | Kanama |
| 339 | ID_acd346a08 | 1 | 1 | Kanama |
| 340 | ID_b03b72caf | 1 | 1 | Kanama |
| 341 | ID_b14965cc0 | 1 | 1 | Kanama |
| 342 | ID_b7f5b5dc6 | 1 | 1 | Kanama |
| 343 | ID_b81f87355 | 1 | 1 | Kanama |
| 344 | ID_b89a48cf6 | 1 | 1 | Kanama |
| 345 | ID_b9d81de91 | 1 | 1 | Kanama |
| 346 | ID_bcdb02bae | 1 | 1 | Kanama |
| 347 | ID_be55c0449 | 1 | 1 | Kanama |
| 348 | ID_bf6da4f8e | 1 | 1 | Kanama |
| 349 | ID_c18fd40b7 | 1 | 1 | Kanama |
| 350 | ID_c8011d632 | 1 | 1 | Kanama |
| 351 | ID_c838a80ae | 1 | 1 | Kanama |
| 352 | ID_c8f665e09 | 1 | 1 | Kanama |
| 353 | ID_c91587fa6 | 1 | 1 | Kanama |
| 354 | ID_c9405030c | 1 | 1 | Kanama |
| 355 | ID_c94e05ff1 | 1 | 1 | Kanama |
| 356 | ID_c9504b01f | 1 | 1 | Kanama |
| 357 | ID_ca42b49ba | 1 | 1 | Kanama |
| 358 | ID_cae20e8e6 | 1 | 1 | Kanama |
| 359 | ID_cc5f690a0 | 1 | 1 | Kanama |
| 360 | ID_cc78f9b17 | 1 | 1 | Kanama |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|---------------------------|----------|----------------|--------|
| 361 | ID_cd3ad7213 | 1 | 1 | Kanama |
| 362 | ID_cde2d3e69 | 1 | 1 | Kanama |
| 363 | ID_d00ccb179 | 1 | 1 | Kanama |
| 364 | ID_d1fdae2b0 | 1 | 1 | Kanama |
| 365 | ID_d29b0df28 | 1 | 1 | Kanama |
| 366 | ID_d30847617 | 1 | 1 | Kanama |
| 367 | ID_d3f30a952 | 1 | 1 | Kanama |
| 368 | ID_d6ab45e29 | 1 | 1 | Kanama |
| 369 | ID_d79843124 | 1 | 1 | Kanama |
| 370 | ID_d843d4560 | 1 | 1 | Kanama |
| 371 | ID_d85dca00d | 1 | 1 | Kanama |
| 372 | ID_d8d386283 | 1 | 1 | Kanama |
| 373 | ID_e052ee9a7 | 1 | 1 | Kanama |
| 374 | ID_e096d140a | 1 | 1 | Kanama |
| 375 | ID_e1f9dce2b | 1 | 1 | Kanama |
| 376 | ID_e29533718 | 1 | 1 | Kanama |
| 377 | ID_e30416b36 | 1 | 1 | Kanama |
| 378 | ID_e39cd325e | 1 | 1 | Kanama |
| 379 | ID_e42e11bfe | 1 | 1 | Kanama |
| 380 | ID_e4f805f3f | 1 | 1 | Kanama |
| 381 | ID_e53f41c57 | 1 | 1 | Kanama |
| 382 | ID_e56f7ab2d | 1 | 1 | Kanama |
| 383 | ID_e7499d8de | 1 | 1 | Kanama |
| 384 | ID_e763c734d | 1 | 1 | Kanama |
| 385 | ID_e771666de | 1 | 1 | Kanama |
| 386 | ID_eae9d6f91 | 1 | 1 | Kanama |
| 387 | ID_ed805d300 | 1 | 1 | Kanama |
| 388 | ID_f2acf1fe3 | 1 | 1 | Kanama |
| 389 | ID_f356fe5a1 | 1 | 1 | Kanama |
| 390 | ID_f3da8f643 | 1 | 1 | Kanama |
| 391 | ID_f47db2801 | 1 | 1 | Kanama |
| 392 | ID_f5e75491c | 1 | 1 | Kanama |
| 393 | ID_f6fd944e4 | 1 | 1 | Kanama |
| 394 | ID_f98d45534 | 1 | 1 | Kanama |
| 395 | SMIR.Brain.XX.O.CT.345569 | 2,3 | 2 | Normal |
| 396 | SMIR.Brain.XX.O.CT.345886 | 1 | 1 | Normal |
| 397 | SMIR.Brain.XX.O.CT.345914 | 1 | 1 | Normal |
| 398 | SMIR.Brain.XX.O.CT.345921 | 2 | 1 | Normal |
| 399 | SMIR.Brain.XX.O.CT.346103 | 20 | 1 | Normal |
| 400 | SMIR.Brain.XX.O.CT.346110 | 21,22 | 2 | Normal |
| 401 | SMIR.Brain.XX.O.CT.346124 | 11,12 | 2 | Normal |
| 402 | SMIR.Brain.XX.O.CT.346166 | 11 | 1 | Normal |
| 403 | SMIR.Brain.XX.O.CT.345611 | 5,7,8 | 3 | Normal |
| 404 | SMIR.Brain.XX.O.CT.346173 | 11,12 | 2 | Normal |
| 405 | SMIR.Brain.XX.O.CT.346180 | 10,11 | 2 | Normal |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 406 | ID_02014d71e | 1 | 1 | Normal |
| 407 | ID_02204ef39 | 1 | 1 | Normal |
| 408 | ID_030acb5f0 | 1 | 1 | Normal |
| 409 | ID_03ebf2795 | 1 | 1 | Normal |
| 410 | ID_04b0da793 | 1 | 1 | Normal |
| 411 | ID_054b24f26 | 1 | 1 | Normal |
| 412 | ID_05bfde0c6 | 1 | 1 | Normal |
| 413 | ID_06277a647 | 1 | 1 | Normal |
| 414 | ID_064c64198 | 1 | 1 | Normal |
| 415 | ID_0748f9f06 | 1 | 1 | Normal |
| 416 | ID_085f35ae0 | 1 | 1 | Normal |
| 417 | ID_093dec088 | 1 | 1 | Normal |
| 418 | ID_09fc27a88 | 1 | 1 | Normal |
| 419 | ID_0b3361e8f | 1 | 1 | Normal |
| 420 | ID_0cb3622a6 | 1 | 1 | Normal |
| 421 | ID_0e26dad0b | 1 | 1 | Normal |
| 422 | ID_128bdaa23 | 1 | 1 | Normal |
| 423 | ID_1311b3748 | 1 | 1 | Normal |
| 424 | ID_16f3dc257 | 1 | 1 | Normal |
| 425 | ID_1710e8c07 | 1 | 1 | Normal |
| 426 | ID_174c5dd4d | 1 | 1 | Normal |
| 427 | ID_191ad983b | 1 | 1 | Normal |
| 428 | ID_1927f4292 | 1 | 1 | Normal |
| 429 | ID_196eb0ac9 | 1 | 1 | Normal |
| 430 | ID_1d134a620 | 1 | 1 | Normal |
| 431 | ID_1d8fca96e | 1 | 1 | Normal |
| 432 | ID_20ba7746f | 1 | 1 | Normal |
| 433 | ID_2235d5993 | 1 | 1 | Normal |
| 434 | ID_223aea9d7 | 1 | 1 | Normal |
| 435 | ID_226d08d83 | 1 | 1 | Normal |
| 436 | ID_227a7a538 | 1 | 1 | Normal |
| 437 | ID_229e528a8 | 1 | 1 | Normal |
| 438 | ID_242363c5a | 1 | 1 | Normal |
| 439 | ID_273603bbf | 1 | 1 | Normal |
| 440 | ID_27de23818 | 1 | 1 | Normal |
| 441 | ID_2971b72d4 | 1 | 1 | Normal |
| 442 | ID_29b68062d | 1 | 1 | Normal |
| 443 | ID_2a2ddeecb | 1 | 1 | Normal |
| 444 | ID_2a57e4ef8 | 1 | 1 | Normal |
| 445 | ID_2b2d4603c | 1 | 1 | Normal |
| 446 | ID_2bd66afd5 | 1 | 1 | Normal |
| 447 | ID_2c096fc76 | 1 | 1 | Normal |
| 448 | ID_2c1e3fbc1 | 1 | 1 | Normal |
| 449 | ID_2cf616eb6 | 1 | 1 | Normal |
| 450 | ID_2d4d3d44f | 1 | 1 | Normal |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 451 | ID_2fc93ce42 | 1 | 1 | Normal |
| 452 | ID_316ba46e1 | 1 | 1 | Normal |
| 453 | ID_324e138f2 | 1 | 1 | Normal |
| 454 | ID_3264f792a | 1 | 1 | Normal |
| 455 | ID_33655dd72 | 1 | 1 | Normal |
| 456 | ID_372e5f155 | 1 | 1 | Normal |
| 457 | ID_3947e6d7c | 1 | 1 | Normal |
| 458 | ID_39eb5d162 | 1 | 1 | Normal |
| 459 | ID_3b9e202ff | 1 | 1 | Normal |
| 460 | ID_3c4549f03 | 1 | 1 | Normal |
| 461 | ID_3c9e11721 | 1 | 1 | Normal |
| 462 | ID_3ca88a931 | 1 | 1 | Normal |
| 463 | ID_3f5ed4234 | 1 | 1 | Normal |
| 464 | ID_3fd00ea40 | 1 | 1 | Normal |
| 465 | ID_3fd4e031b | 1 | 1 | Normal |
| 466 | ID_4160ff7f8 | 1 | 1 | Normal |
| 467 | ID_416b48301 | 1 | 1 | Normal |
| 468 | ID_4189548d1 | 1 | 1 | Normal |
| 469 | ID_41cc14c7a | 1 | 1 | Normal |
| 470 | ID_4244ed9d7 | 1 | 1 | Normal |
| 471 | ID_432badc8e | 1 | 1 | Normal |
| 472 | ID_45add01c3 | 1 | 1 | Normal |
| 473 | ID_46291efd1 | 1 | 1 | Normal |
| 474 | ID_463dac8ad | 1 | 1 | Normal |
| 475 | ID_46653daa6 | 1 | 1 | Normal |
| 476 | ID_46730561a | 1 | 1 | Normal |
| 477 | ID_471220e4d | 1 | 1 | Normal |
| 478 | ID_47a83bbd2 | 1 | 1 | Normal |
| 479 | ID_491c2e593 | 1 | 1 | Normal |
| 480 | ID_4abed4c32 | 1 | 1 | Normal |
| 481 | ID_4b997afbe | 1 | 1 | Normal |
| 482 | ID_4c3f16712 | 1 | 1 | Normal |
| 483 | ID_4cbd638b6 | 1 | 1 | Normal |
| 484 | ID_4d815d013 | 1 | 1 | Normal |
| 485 | ID_4dd40cf72 | 1 | 1 | Normal |
| 486 | ID_517c583af | 1 | 1 | Normal |
| 487 | ID_5386f4b10 | 1 | 1 | Normal |
| 488 | ID_539c72ce7 | 1 | 1 | Normal |
| 489 | ID_54c042ff9 | 1 | 1 | Normal |
| 490 | ID_559aa6901 | 1 | 1 | Normal |
| 491 | ID_55ad51a4d | 1 | 1 | Normal |
| 492 | ID_56540e7ef | 1 | 1 | Normal |
| 493 | ID_56b25c8d9 | 1 | 1 | Normal |
| 494 | ID_5762d31f3 | 1 | 1 | Normal |
| 495 | ID_57818c09e | 1 | 1 | Normal |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 496 | ID_586db5afa | 1 | 1 | Normal |
| 497 | ID_5919a7c3a | 1 | 1 | Normal |
| 498 | ID_5b27b934f | 1 | 1 | Normal |
| 499 | ID_5bc862a16 | 1 | 1 | Normal |
| 500 | ID_5cad69f4c | 1 | 1 | Normal |
| 501 | ID_5d20444ae | 1 | 1 | Normal |
| 502 | ID_5dacfd87a | 1 | 1 | Normal |
| 503 | ID_5fa9e5776 | 1 | 1 | Normal |
| 504 | ID_601dba3ea | 1 | 1 | Normal |
| 505 | ID_61977d234 | 1 | 1 | Normal |
| 506 | ID_61e857aa9 | 1 | 1 | Normal |
| 507 | ID_61f514554 | 1 | 1 | Normal |
| 508 | ID_6299d96ab | 1 | 1 | Normal |
| 509 | ID_62ec85c41 | 1 | 1 | Normal |
| 510 | ID_6308ed36d | 1 | 1 | Normal |
| 511 | ID_647b6e8d7 | 1 | 1 | Normal |
| 512 | ID_64c0721d9 | 1 | 1 | Normal |
| 513 | ID_6558b1358 | 1 | 1 | Normal |
| 514 | ID_65af5120a | 1 | 1 | Normal |
| 515 | ID_65b527139 | 1 | 1 | Normal |
| 516 | ID_6723f480a | 1 | 1 | Normal |
| 517 | ID_67bdf13a4 | 1 | 1 | Normal |
| 518 | ID_68558d316 | 1 | 1 | Normal |
| 519 | ID_6996ee4ad | 1 | 1 | Normal |
| 520 | ID_69b761399 | 1 | 1 | Normal |
| 521 | ID_6b0c7ed46 | 1 | 1 | Normal |
| 522 | ID_6b4c329a5 | 1 | 1 | Normal |
| 523 | ID_6b69b9320 | 1 | 1 | Normal |
| 524 | ID_6d92bbb7c | 1 | 1 | Normal |
| 525 | ID_6dc9647a8 | 1 | 1 | Normal |
| 526 | ID_6f1a9d9b0 | 1 | 1 | Normal |
| 527 | ID_718c25b16 | 1 | 1 | Normal |
| 528 | ID_71f66f567 | 1 | 1 | Normal |
| 529 | ID_7437a7eee | 1 | 1 | Normal |
| 530 | ID_74c91c1a5 | 1 | 1 | Normal |
| 531 | ID_7567b6e9e | 1 | 1 | Normal |
| 532 | ID_756b53093 | 1 | 1 | Normal |
| 533 | ID_75f0c7adf | 1 | 1 | Normal |
| 534 | ID_76175cb7b | 1 | 1 | Normal |
| 535 | ID_773ec867a | 1 | 1 | Normal |
| 536 | ID_77fe5dbc8 | 1 | 1 | Normal |
| 537 | ID_7a676856b | 1 | 1 | Normal |
| 538 | ID_7b54b578e | 1 | 1 | Normal |
| 539 | ID_7d7e6bbbf | 1 | 1 | Normal |
| 540 | ID_7d7e7742e | 1 | 1 | Normal |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 541 | ID_7dd3f5d23 | 1 | 1 | Normal |
| 542 | ID_808c0e8b4 | 1 | 1 | Normal |
| 543 | ID_82d63fc84 | 1 | 1 | Normal |
| 544 | ID_8349526dd | 1 | 1 | Normal |
| 545 | ID_834e439a0 | 1 | 1 | Normal |
| 546 | ID_83bcb3e52 | 1 | 1 | Normal |
| 547 | ID_8472b4de8 | 1 | 1 | Normal |
| 548 | ID_84a1fe3c0 | 1 | 1 | Normal |
| 549 | ID_84c1ceca0 | 1 | 1 | Normal |
| 550 | ID_858b35c4a | 1 | 1 | Normal |
| 551 | ID_860c2af40 | 1 | 1 | Normal |
| 552 | ID_86b75fa34 | 1 | 1 | Normal |
| 553 | ID_86e0db3e8 | 1 | 1 | Normal |
| 554 | ID_89789fe7d | 1 | 1 | Normal |
| 555 | ID_8b696fefb | 1 | 1 | Normal |
| 556 | ID_8bf4b02c1 | 1 | 1 | Normal |
| 557 | ID_8cb876ee5 | 1 | 1 | Normal |
| 558 | ID_8d1d4561d | 1 | 1 | Normal |
| 559 | ID_8dc1999a1 | 1 | 1 | Normal |
| 560 | ID_8fbb15025 | 1 | 1 | Normal |
| 561 | ID_8fbb71288 | 1 | 1 | Normal |
| 562 | ID_90165c2e5 | 1 | 1 | Normal |
| 563 | ID_9017b56ce | 1 | 1 | Normal |
| 564 | ID_912e886c2 | 1 | 1 | Normal |
| 565 | ID_933e55672 | 1 | 1 | Normal |
| 566 | ID_9366d1d4c | 1 | 1 | Normal |
| 567 | ID_93c7dd9c5 | 1 | 1 | Normal |
| 568 | ID_93d64323e | 1 | 1 | Normal |
| 569 | ID_93f4c7426 | 1 | 1 | Normal |
| 570 | ID_941929e2d | 1 | 1 | Normal |
| 571 | ID_9472c25b7 | 1 | 1 | Normal |
| 572 | ID_96d989c25 | 1 | 1 | Normal |
| 573 | ID_974fcb059 | 1 | 1 | Normal |
| 574 | ID_978167c6e | 1 | 1 | Normal |
| 575 | ID_97e284174 | 1 | 1 | Normal |
| 576 | ID_9983e1073 | 1 | 1 | Normal |
| 577 | ID_9b0d1d011 | 1 | 1 | Normal |
| 578 | ID_9b3125334 | 1 | 1 | Normal |
| 579 | ID_9b4982dfc | 1 | 1 | Normal |
| 580 | ID_9b5b195e4 | 1 | 1 | Normal |
| 581 | ID_9b6803ba4 | 1 | 1 | Normal |
| 582 | ID_9beaaeac2 | 1 | 1 | Normal |
| 583 | ID_9c78e92ba | 1 | 1 | Normal |
| 584 | ID_9cac5783f | 1 | 1 | Normal |
| 585 | ID_9eab5fce7 | 1 | 1 | Normal |

| SN | Görüntü ID | Kesit No | Görüntü Sayısı | Sınıfı |
|-----|--------------|----------|----------------|--------|
| 586 | ID_9f0d1509f | 1 | 1 | Normal |
| 587 | ID_9f97da3c0 | 1 | 1 | Normal |
| 588 | ID_a01e212c2 | 1 | 1 | Normal |
| 589 | ID_a06dd2af8 | 1 | 1 | Normal |
| 590 | ID_a0ddfd93 | 1 | 1 | Normal |
| 591 | ID_a1829614a | 1 | 1 | Normal |
| 592 | ID_a2820e2f4 | 1 | 1 | Normal |
| 593 | ID_a34f5f20b | 1 | 1 | Normal |
| 594 | ID_a38f74b1a | 1 | 1 | Normal |
| 595 | ID_a3bfa362f | 1 | 1 | Normal |
| 596 | ID_a40b9757e | 1 | 1 | Normal |
| 597 | ID_a42e08b28 | 1 | 1 | Normal |
| 598 | ID_a4398c5a8 | 1 | 1 | Normal |
| 599 | ID_a44d4853d | 1 | 1 | Normal |
| 600 | ID_a595fa940 | 1 | 1 | Normal |
| 601 | ID_a60f414ef | 1 | 1 | Normal |
| 602 | ID_a6f6d9a6a | 1 | 1 | Normal |
| 603 | ID_a6f872927 | 1 | 1 | Normal |
| 604 | ID_a708a2f86 | 1 | 1 | Normal |
| 605 | ID_a79af37d4 | 1 | 1 | Normal |
| 606 | ID_a7dfc5fab | 1 | 1 | Normal |
| 607 | ID_a7f57b612 | 1 | 1 | Normal |
| 608 | ID_a87b5f8a5 | 1 | 1 | Normal |
| 609 | ID_a8d215581 | 1 | 1 | Normal |
| 610 | ID_a8d35aad2 | 1 | 1 | Normal |
| 611 | ID_abd0cebb6 | 1 | 1 | Normal |
| 612 | ID_ac1807f79 | 1 | 1 | Normal |
| 613 | ID_ac3828e9a | 1 | 1 | Normal |
| 614 | ID_ac4f42d2a | 1 | 1 | Normal |
| 615 | ID_ad2e19d82 | 1 | 1 | Normal |
| 616 | ID_ae5749005 | 1 | 1 | Normal |
| 617 | ID_ae93f1341 | 1 | 1 | Normal |
| 618 | ID_af500f183 | 1 | 1 | Normal |
| 619 | ID_b00c5a9f6 | 1 | 1 | Normal |
| 620 | ID_b09192b46 | 1 | 1 | Normal |
| 621 | ID_b0ce01e1f | 1 | 1 | Normal |
| 622 | ID_b1706c939 | 1 | 1 | Normal |
| 623 | ID_b33cf1fee | 1 | 1 | Normal |
| 624 | ID_b35007d20 | 1 | 1 | Normal |
| 625 | ID_b38d45d88 | 1 | 1 | Normal |
| 626 | ID_b3a2a8b29 | 1 | 1 | Normal |
| 627 | ID_b3f535c9d | 1 | 1 | Normal |
| 628 | ID_b637c12e9 | 1 | 1 | Normal |
| 629 | ID_b6ca5c683 | 1 | 1 | Normal |
| 630 | ID_b7aba2345 | 1 | 1 | Normal |

