



**SEREBROVASKÜLER HASTALIKLARIN TEŞHİSİ İÇİN YAPAY ZEKA
TABANLI KARAR DESTEK SİSTEMİ**

Furkan KUTAN

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

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2023

ETİK BEYAN

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

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

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

Furkan KUTAN

10/07/2023

SEREBROVASKÜLER HASTALIKLARIN TEŞHİSİ İÇİN YAPAY ZEKA TABANLI KARAR DESTEK SİSTEMİ

(Yüksek Lisans Tezi)

Furkan KUTAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2023

ÖZET

Serebrovasküler hastalıklar, beyni besleyen damar bölümleri üzerinde, kan akışının zayıflaması, durması veya damarların yırtılması sonucunda beyinde hasara yol açan ve beyin fonksiyonlarında ciddi bozukluklara sebep olan hastalık grubudur. Serebrovasküler hastalıklar, dünya genelinde ölüm nedenleri arasında üçüncü sırada yer alırken, hastalık sonrasında engelli kalma oranı açısından ilk sırada yer almaktadır. Bu nedenle, beyin damarlarının oluşturduğu vasküler yapının detaylı bir şekilde incelenmesi, erken hastalık teşhisi ve cerrahi planlama gibi klinik uygulamalar için büyük önem taşımaktadır. Klinik uygulamalarda, radyologlar tarafından kullanılan medikal görüntüleme araçlarındaki damar segmentasyon işlemi, manuel veya yarı otomatik bir şekilde gerçekleştirilebilmektedir. Genellikle bu işlemlerde kullanılan algoritmalar kural tabanlı veya el ile öz nitelik çıkartım işlemini içerdiğinden, karmaşık yapıdaki anjiyografi görüntülerinde damar segmentasyon başarısının düşük olmasına sebebiyet verebilmektedir. Bu nedenle, yapılan tez çalışmasının ilk aşamasında Hesse matris tabanlı filtreleme, bağlı birleşen analizi ve bölge büyütme algoritması gibi klasik görüntü işleme tabanlı yöntemler kullanılarak damar bölümlerinin segmentasyonu sağlanmıştır. İkinci aşamada ise segmentasyon başarısını artırmak amacıyla son yıllarda bilgisayarlı görü alanında oldukça popüler olan derin öğrenme teknikleri kullanılarak, klinik kullanım için yüksek doğruluk oranıyla otomatik ve hızlı bir şekilde damar segmentasyonu gerçekleştirilmiştir. Derin öğrenme tabanlı segmentasyon işleminde ilk olarak majör serebral arterlere odaklanılmış olup bu bölgelerin segmentasyonu amacıyla UNet, ResUNet, ResUNet++ ve TransUNet gibi medikal görüntüleme alanında yaygın olarak kullanılan derin öğrenme mimarileri kullanılarak performansları karşılaştırılmıştır. Çalışmanın deneysel sonuçları incelendiğinde damar segmentasyon probleminde ResUNet++ mimarisinin diğer mimarilere kıyasla %91.6 ortalama Jaccard indeks değeri ile en yüksek başarı sonucu elde ettiği görülmüştür. Çalışmanın ilerleyen kısımlarında ise majör arterlerin yanı sıra diğer arter bölümlerinin de ResUNet++ mimarisi vasıtasıyla bölütlenmesi sağlanarak önerilen yaklaşımın, klasik kural tabanlı görüntü işleme algoritmalarına göre daha başarılı sonuçlar elde ettiği gözlemlenmiştir.

Bilim Kodu : 90542

Anahtar Kelimeler : Manyetik rezonans anjiyografi, derin öğrenme, görüntü işleme, damar segmentasyonu, serebrovasküler hastalıklar

Sayfa Adedi : 139

Danışman : Doç. Dr. Uğurhan KUTBAY

ARTIFICIAL INTELLIGENCE BASED DECISION SUPPORT SYSTEM FOR
DIAGNOSIS OF CEREBROVASCULAR DISEASE

(M. Sc. Thesis)

Furkan KUTAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2023

ABSTRACT

Cerebrovascular diseases are a group of diseases that cause damage to the brain and serious disorders in brain functions as a result of weakening, stopping, or tearing of the blood flow in the vascular sections that feed the brain. While cerebrovascular diseases are in third place among the causes of death worldwide, they are in first place in terms of the rate of being disabled after the disease. Therefore, a detailed examination of the vascular structure formed by the cerebral vessels is of great importance for clinical applications such as early disease diagnosis and surgical planning. In clinical applications, vessel segmentation in medical imaging tools used by radiologists can be performed manually or semi-automatically. Since the algorithms generally used in these processes involve rule-based or manual feature extraction, they may cause low vessel segmentation success in complex angiography images. For this reason, in the first stage of the thesis study, segmentation of vessel segments is provided by using classical image processing-based methods such as Hesse matrix-based filtering, associated component analysis and region amplification algorithm. In the second stage, in order to increase the segmentation success, using deep learning techniques, which have been very popular in the field of computer vision in recent years, automatic and rapid vessel segmentation was performed with high accuracy for clinical use. In the deep learning-based segmentation process, the major cerebral arteries were focused first, and their performances were compared using deep learning architectures commonly used in the medical imaging field such as UNet, ResUNet, ResUNet++ and TransUNet for the segmentation of these regions. When the experimental results of the study were examined, it was seen that the ResUNet++ architecture achieved the highest success with an average Jaccard index value of 91.6% compared to other architectures in the vessel segmentation problem. In the later parts of the study, it was observed that the proposed approach achieved more successful results than the classical rule-based image processing algorithms by ensuring that the major arteries as well as other artery sections were segmented through the ResUNet++ architecture.

Science Code : 90542

Key Words : Magnetic resonance angiography, deep learning, image processing, vessel segmentation, cerebrovascular diseases

Page Number : 139

Supervisor : Assoc. Prof. Dr. Uğurhan KUTBAY

TEŞEKKÜR

Tez çalışmam süresince her zaman olumlu, yol gösterici ve motive edici katkılarından dolayı değerli danışmanım Doç. Dr. Uğurhan KUTBAY ile medikal görüntüleme alanında bilgilerini bizlere aktaran ve verilerinin etiketlenme sürecinde yardımcı olan Ankara Üniversitesi Radyoloji bölümünde görevli radyolog Prof. Dr. Oktay ALGIN hocama teşekkürü borç bilirim. Çalışmam boyunca desteklerini hiçbir zaman bırakmayan değerli ailem, müstakbel eşim ve arkadaşlarıma teşekkür ederim.

Furkan KUTAN

Haziran, 2023

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ŞEKİLLERİN LİSTESİ.....	ix
ÇİZELGELERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xvi
1. GİRİŞ.....	1
2. LİTERATÜR ÇALIŞMALARI.....	5
2.1. Görüntü İşleme Tabanlı Literatür Çalışmaları	5
2.2. Derin Öğrenme Tabanlı Literatür Çalışmaları	8
3. MATERYAL VE YÖNTEM	13
3.1. Medikal Görüntüleme Sistemleri	13
3.2. Görüntü İşleme.....	16
3.2.1. Gaussian filtreleme.....	19
3.2.2. Hesse matrisi	21
3.3. Yapay Zekâ	25
3.4. Makine Öğrenmesi	26
3.4.1. Denetimli öğrenme	27
3.4.2. Denetimsiz öğrenme	29
3.5. Derin Öğrenme.....	30
3.5.1. Yapay sinir ağları	31
3.5.2. Evrimsel sinir ağları	37
3.5.3. Yinelemeli sinir ağları	45

	Sayfa
3.5.4. Evrişimsel sinir ağı modelleri	54
3.6. Performans Değerlendirme Metrikleri	59
3.6.1. Piksel doğruluk metriği.....	60
3.6.2. Kesinlik metriği.....	60
3.6.3. Duyarlılık metriği.....	61
3.6.4. F Değeri (F Score).....	61
3.6.5. Jaccard indeksi(Intersection Over Union).....	61
4. GERÇEKLEŞTİRİLEN UYGULAMALAR VE SONUÇLARIN İNCELENMESİ	63
4.1. Çalışma Kapsamında Kullanılan Veri Seti	63
4.2. Görüntü İşleme Teknikleriyle Damar Bölümlerinin Segmentasyonu.....	64
4.2.1. Sato filtreleme	66
4.2.2. Bağlı bileşenlerin etiketlenmesi.....	74
4.2.3. Bölge büyütme tekniği.....	78
4.2.4. Görüntü işleme sonuçlarının değerlendirilmesi.....	82
4.3. Derin Öğrenme Teknikleriyle Damar Bölümlerinin Segmentasyonu.....	83
4.3.1. Etiketli veri setinin oluşturulması	83
4.3.2. Yapay zeka modellerinin eğitim hazırlıkları	92
4.3.3. Derin öğrenme tabanlı ana serebral arterlerin segmentasyonu.....	98
4.3.4. Derin öğrenme tabanlı serebral arterlerin segmentasyonu.....	108
5. TARTIŞMA	127
6. SONUÇLAR VE ÖNERİLER.....	129
KAYNAKLAR	133
ÖZGEÇMİŞ	141

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Dijital görüntü elde etme sistemi	16
Şekil 3.2. Analog – Dijital sinyal dönüşümü	17
Şekil 3.3. İki boyutlu görüntü matris örneği	18
Şekil 3.4. İkinci dereceden Gaussian filtre gösterimi	19
Şekil 3.5. Laplacian of Gaussian filtre gösterimi	20
Şekil 3.6. N boyutlu Hesse matrisi.....	21
Şekil 3.7. Silindirik yüzeyde öz değer ve öz vektörlerin gösterimi	22
Şekil 3.8. Düz yüzeydeki öz değer ve öz vektörlerin gösterimi	23
Şekil 3.9. Üç boyutlu görüntü matrisi	24
Şekil 3.10. Yapay zekâ alt alanlarının hiyerarşik gösterimi	25
Şekil 3.11. Makine öğrenmesini oluşturan alt alanların gösterimi	26
Şekil 3.12. Denetimli öğrenme blok diyagramı	27
Şekil 3.13. Medikal bölütleme ve tespit problem örneği	28
Şekil 3.14. Denetimsiz öğrenme blok diyagramı.....	29
Şekil 3.15. Derin öğrenmeyi oluşturan alt alanların gösterimi	30
Şekil 3.16. Biyolojik sinir ağı hücresi.....	32
Şekil 3.17. Yapay sinir hücresi	33
Şekil 3.18. Yapay sinir ağı katmanları.....	33
Şekil 3.19. Tek katmanlı yapay sinir ağı.....	34
Şekil 3.20. Tek katmanlı çeşitli yapay sinir ağları.....	35
Şekil 3.21. Çok katmanlı yapay sinir ağı	36
Şekil 3.22. Evrişimli sinir ağları mimarisi	37
Şekil 3.23. Konvolüsyon işlemi blok gösterimi.....	39
Şekil 3.24. Konvolüsyon işlem gösterimi	40

Şekil	Sayfa
Şekil 3.25. Evrişimsel sinir ağlarında evrişim işlemi	41
Şekil 3.26. Maksimum ve ortalama havuzlama katman	42
Şekil 3.27. Sıkıştır ve uyarma bloğu.....	43
Şekil 3.28. Atrous uzamsal piramit havuzlama katmanı	44
Şekil 3.29. Geleneksel yinelemeli sinir ağı mimarisi	45
Şekil 3.30. Yinelemeli sinir ağı hücre gösterimi	46
Şekil 3.31. Geçitli tekrarlayan ünite gösterimi	47
Şekil 3.32. Uzun kısa süreli bellek hücre gösterimi	48
Şekil 3.33. Ekleme tarzında dikkat mekanizması blok gösterimi	49
Şekil 3.34. Nokta çarpım dikkat mekanizması blok gösterimi	51
Şekil 3.35. Dönüştürücü mekanizması blok gösterimi	52
Şekil 3.36. Görüntü dönüştürücü mimarisi	53
Şekil 3.37. U-Net mimarisi	55
Şekil 3.38. ResUNet mimarisi	56
Şekil 3.39. ResUNet++ mimarisi.....	57
Şekil 3.40. TransUNet mimarisi	58
Şekil 4.1. Görüntü işleme tabanlı sistem akış diyagramı.....	67
Şekil 4.2. Üç boyutlu Hesse görüntü matrisi	67
Şekil 4.3. Farklı bağlantı komşuluklarının gösterimi	74
Şekil 4.4. Derin öğrenme tabanlı sistem akış diyagramı	97
Şekil 4.5. Yitim fonksiyonu plato eğrisi	97
Şekil 4.6. Geliştirilen mimarilerin yitim fonksiyon değerlerinin karşılaştırılması	100
Şekil 4.7. Geliştirilen mimarilerin Jaccard indeks değerlerinin karşılaştırılması	100
Şekil 4.8. Derin öğrenme tabanlı sistem akış diyagramı	100

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Öz değerlerin büyüklüğüne göre geometrik yapıların yorumlanması	24
Çizelge 4.1. Veri setini oluşturan veri dağılımı	64
Çizelge 4.2. Test görüntüleri üzerinde algoritma çıktılarının değerlendirilmesi	64
Çizelge 4.3. Eğitim mimarilerinin parametre bilgileri	98
Çizelge 4.4. Test verisi üzerinde modellerin başarılarının karşılaştırılması	101
Çizelge 4.5. Eğitim mimarisinin parametre bilgileri	109
Çizelge 4.6. Test verisi üzerinde modellerin başarılarının karşılaştırılması	111

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. DSA görüntüleme sistemi.....	13
Resim 3.2. İnme hastasına ait BTA kesit görüntüsü.....	14
Resim 3.3. Anevrizma hastasının ait MRA görüntüsü.....	15
Resim 4.1. Veri seti erişim bilgileri	63
Resim 4.2. İlk hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları.....	70
Resim 4.3. İlk hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları.....	70
Resim 4.4. İlk hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları.....	71
Resim 4.5. İlk hastaya ait 3 boyutlu segmentasyon çıktısı	71
Resim 4.6. İkinci hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları.....	72
Resim 4.7. İkinci hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları.....	72
Resim 4.8. İkinci hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları.....	73
Resim 4.9. İkinci hastaya ait 3 boyutlu segmentasyon çıktısı	73
Resim 4.10. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları	75
Resim 4.11. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları	75
Resim 4.12. İlk hastaya ait bağlı bileşen etiketleme tekniğinin üç boyutlu çıktısı.....	76
Resim 4.13. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları	76
Resim 4.14. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları	77
Resim 4.15. İkinci hastaya ait bağlı bileşen etiketleme tekniğinin üç boyutlu çıktısı	77
Resim 4.16. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları	79
Resim 4.17. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları	79
Resim 4.18. İlk hastaya ait bölge büyütme tekniğinin üç boyutlu çıktısı	80
Resim 4.19. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları	80
Resim 4.20. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları	81
Resim 4.21. İkinci hastaya ait bölge büyütme tekniğinin üç boyutlu çıktısı	81

Resim	Sayfa
Resim 4.22. Farklı bir hastanın algoritma çıktı kesit görüntüsü	82
Resim 4.23. Willis çember bölgesinin MRA görüntülerinde gösterimi	83
Resim 4.24. Görüntü işleme algoritma çıktısı	84
Resim 4.25. Ana serebral arter dışı bölümlerin silinmesiyle oluşan çıktı görüntüsü	85
Resim 4.26. Hollow algoritması vasıtasıyla oluşan çıktı görüntüsü	85
Resim 4.27. Hollow algoritması vasıtasıyla oluşan çıktı görüntüsü	86
Resim 4.28. Hollow algoritması vasıtasıyla oluşan çıktı görüntüsü	86
Resim 4.29. Philips Intera cihazına ait etiketlenmiş kesit görüntüleri	87
Resim 4.30. Siemens Skyra cihazına ait etiketlenmiş kesit görüntüleri	88
Resim 4.31. Siemens Skyra cihazına ait etiketlenmiş kesit görüntüleri	88
Resim 4.32. Siemens Skyra cihaz ilk hastaya ait etiketlenmiş 3D görüntü	89
Resim 4.33. Siemens Skyra cihaz ilk hastaya ait etiketlenmiş 3D görüntü	89
Resim 4.34. Siemens Skyra cihaz ilk hastaya ait etiketlenmiş 3D görüntü	90
Resim 4.35. Siemens Skyra cihaz ikinci hastaya ait etiketlenmiş 3D görüntü	90
Resim 4.36. Siemens Skyra cihaz ikinci hastaya ait etiketlenmiş 3D görüntü	91
Resim 4.37. Siemens Skyra cihaz ikinci hastaya ait etiketlenmiş 3D görüntü	91
Resim 4.38. Philips Intera cihaz üçüncü hastaya ait etiketlenmiş 3D görüntü	92
Resim 4.39. Orijinal ve normalizasyon tekniğinin çıktı görüntüleri	94
Resim 4.40. Çözünürlük standardizasyon işleminin gösterilmesi	95
Resim 4.41. Etiketlenmiş görüntü ve derin öğrenme modelinin tahmin çıktısı	102
Resim 4.42. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı	102
Resim 4.43. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı	102
Resim 4.44. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı	103
Resim 4.45. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı	103

Resim	Sayfa
Resim 4.46. Siemens marka Skyra model hastaya ait etiketlenmiş görüntü	104
Resim 4.47. Siemens marka Skyra model hastaya ait ResUNet++ tahmin çıktısı	104
Resim 4.48. Siemens marka Skyra model hastaya ait çıktıların karşılaştırılması	105
Resim 4.49. Siemens marka Verio model hastaya ait etiketlenmiş görüntü.....	105
Resim 4.50. Siemens marka Verio model hastaya ait ResUNet++ tahmin çıktısı.....	106
Resim 4.51. Siemens marka Skyra model hastaya ait çıktıların karşılaştırılması	106
Resim 4.52. Philips marka Intera model hastaya ait etiketlenmiş görüntü	107
Resim 4.53. Philips marka Intera model hastaya ait ResUNet++ tahmin çıktısı.....	107
Resim 4.54. Philips marka Intera model hastaya ait çıktıların karşılaştırılması	108
Resim 4.55. Philips Intera cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı.....	111
Resim 4.56. Philips Intera cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı.....	112
Resim 4.57. Philips Intera cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı.....	112
Resim 4.58. Philips Intera cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı.....	112
Resim 4.59. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	113
Resim 4.60. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	113
Resim 4.61. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	114
Resim 4.62. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	114
Resim 4.63. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	114
Resim 4.64. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	115
Resim 4.65. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	115
Resim 4.66. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	116
Resim 4.67. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	116
Resim 4.68. Siemens Skyra cihaza ait hasta görüntüsü ve ResUNet++ tahmin çıktısı ..	116
Resim 4.69. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü	117

Resim	Sayfa
Resim 4.70. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü.....	117
Resim 4.71. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü	118
Resim 4.72. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü.....	118
Resim 4.73. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü	119
Resim 4.74. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü.....	119
Resim 4.75. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü	120
Resim 4.76. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü.....	120
Resim 4.77. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü	121
Resim 4.78. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü.....	121
Resim 4.79. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü.	122
Resim 4.80. Siemens Skyra Cihaza Ait ResUNet++ tahmin çıktı görüntüsü.....	122
Resim 4.81. Philips Intera cihaza ait etiketlenmiş hasta çıktı görüntüsü.....	123
Resim 4.82. Philips Intera cihaza ait ResUNet++ tahmin çıktı görüntüsü	123
Resim 4.83. Philips Intera cihaza ait etiketlenmiş hasta çıktı görüntüsü.....	124
Resim 4.84. Philips Intera cihaza ait ResUNet++ tahmin çıktı görüntüsü	124
Resim 4.85. Philips Intera cihaza ait etiketlenmiş hasta çıktı görüntüsü.....	125
Resim 4.86. Philips Intera cihaza ait ResUNet++ tahmin çıktı görüntüsü	125

SİMGELER VE KISALTMALAR

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

Simgeler Açıklamalar

% Yüzde

Kısaltmalar Açıklamalar

BTA	Bilgisayarlı Tomografi Anjiyografi
CCL	Bağlı Birleşen Etiketleme
DSA	Dijital Subtraksiyon Anjiyografi
ESA	Evrişimsel Sinir Ağları
FP	Yanlış Pozitif
FN	Yanlış Negatif
GRU	Geçitli Tekrarlan Ünite
IoU	Jaccard İndeksi
LSTM	Uzun Kısa Süreli Bellek
MRA	Manyetik Rezonans Anjiyografi
MRG	Manyetik Rezonans Görüntüleme
mIoU	Ortalama Jaccard İndeksi
PD	Piksel Doğruluğu
SVH	Serebrovasküler Hastalıklar
TP	Gerçek Pozitif
TN	Gerçek Negatif
US	Mikro Saniye
YSA	Yapay Sinir Ağları

1. GİRİŞ

Serebrovasküler hastalıklar (SVH), genellikle beyin damarlarının yoğunlaştığı bölgelerde beyni besleyen damarların tıkanması veya kanaması sonucu ortaya çıkan hastalık gruplarıdır. SVH beyin bölgesi etkilenmeden fiziksel bir şekilde açık bir belirti göstermezken, belirtiler etkilenen bölgeye göre farklılık gösterebilmektedir. Bazı durumlarda hastalar belirti öncesinde konuşma bozuklukları, hafıza problemleri, görme kayıpları gibi kan akımındaki geçici azalmalar sebebiyle oluşan çeşitli uyarıcı belirtilerle karşılaşabilmektedir. Bu gibi durumlarda hastanın ikinci bir atağı önlemek için koruyucu tedaviye alınması gerekmektedir [1].

Günümüzde SVH grubuna çok sayıda hastalık dâhil olsa da inme ve anevrizmalar bu hastalıkların klinik düzeyde en çok karşılaşılan biçimleridir. İnme, halk arasında felç olarak bilinen bu hastalık, beyni besleyen damarların tıkanması veya kanaması sonucu ortaya çıkmaktadır. Damarlarındaki tıkanma veya kanama sonucunda ilgili beyin bölgesine yeterli miktarda oksijen ve gerekli beslenme sağlanmadığından bölge üzerinde yer alan hücrelerde hasar meydana gelmektedir. Anevrizma ise genellikle damarların yoğunlaştığı yerlerde, kan damarları duvarlarının zayıflığından kaynaklanan damarlardaki şişmelerdir. Bu şişmeler, gereğinden fazla zayıflayan damar duvarlarının yırtılmasına ya da patlamasına sebep olabilmektedir. Genellikle yırtılmalar sonucunda oluşan beyin kanamaları kişilerin felç olmasına sebebiyet verebilirken, anevrizmaların yırtılması ise kanamanın şiddetine bağlı olarak beyin hasarlarına ya da ölümle sonuçlanmaktadır.

Dünya genelinde SVH, ölüm nedenleri arasında üçüncü sırada yer alırken, hastalık sonrasında engelli kalma oranı açısından ilk sıralarda yer almaktadır [2]. Bu sebeple serebrovasküler hastalıklar kapsamında beyin damarlarının oluşturduğu vasküler yapının detaylı bir şekilde incelenmesi erken hastalık teşhisi ve cerrahi planlama gibi birçok klinik uygulama açısından oldukça önemlidir. Bu durum vasküler yapının detaylı incelenebilmesi ve içerisindeki akan kanın görselleştirilebilmesi için çeşitli tıbbi görüntüleme teknolojilerinin geliştirilmesine olanak sağlamıştır. Böylece radyolog gelişen medikal teknolojiler sayesinde hastaların durumları hakkında değerlendirmeler yaparak teşhis imkânı gerçekleştirmektedir.

Radyologlar tarafından SVH tespitinde, Manyetik Rezonans Anjiyografi (MRA), Dijital Subtraksiyon Anjiyografi (DSA) ve Bilgisayarlı Tomografi Anjiyografi (BTA) hastalığın türü ve derecesine göre sıklıkla kullanılan medikal görüntüleme teknikleridir. DSA görüntüleme tekniği invazif bir yöntemdir ve çekim aşaması öncesinde hastaya radyo aktif maddeler damardan enjekte edilmektedir. Görüntüleme esnasında ise bu radyo aktif maddenin yaydığı ışımlar cihaz tarafından algılanmaktadır. MRA görüntüleme tekniği, DSA ve CTA tekniğine kıyasla invazif olmayan görüntüleme yöntemleridir [3]. MRA görüntüleme tekniği sırasında cihaz tarafından hastaya sabit bir manyetik alan verilirken, CTA ve DSA görüntüleme tekniğinin de ise hasta X-ışınlarına maruz kalarak iyonize radyasyon durumlarına sebep olabilmektedir. Görüntü oluşturma aşamasında ise bu sinyaller üzerinde meydana gelen zayıflamalar cihaz içerisinde yer alan alıcı sensörler vasıtasıyla algılanarak görüntü formatına dönüştürülmektedir.

SVH tespitinde radyologlar medikal görüntüleme teknikleri vasıtasıyla elde edilmiş görüntüler içerisindeki damarların çaplarını, çevresel kalınlıklarını, düzensizliklerini ve tıkanıklıklarını değerlendirerek, hastalık teşhisi koymaktadırlar. Klinik uygulamalarda bu incelemelerin yapılabilmesi için radyologlar tarafından çeşitli medikal görüntüleme araçlarından faydalanılmaktadır. Kullanılan bu görüntüleme araçlarındaki damar segmentasyon işlemi çoğunlukla manuel veya yarı otomatik bir şekilde gerçekleştirilmektedir.

Manuel bir şekilde gerçekleştirilen damar segmentasyon işlemi gözlemciler arası değişkenlik gösterebildiğinden hata yapmaya açık olduğu gibi zaman açısından da radyologlar açısından oldukça maliyetli olmaktadır. Benzer şekilde yarı otomatik bir şekilde kullanılan yöntemlerdeki algoritmalar, kural tabanlı veya el ile öz nitelik çıkartım işlemini içerdiğinden karmaşık yapıdaki anjiyografi görüntülerindeki vasküler yapının çıkartılmasında başarı oranının düşük olmasına sebebiyet verebilmektedir. Bu sebeple ilerleyen yıllarda gerçekleştirilen araştırmalar, daha hızlı ve daha doğru otomatik damar segmentasyon yöntemleri geliştirmeye odaklanmıştır [4]. Bu kapsamda geliştirilen tam otomatik damar segmentasyon araçları maliyetli olmak ile beraber performans açısından çeşitli dezavantajları yer almaktadır. Bu nedenle radyologların klinikte hastalık teşhisinde veya cerrahi planlamada kullanabileceği yüksek başarı sağlayan ve hızlı bir şekilde çıktı veren damar segmentasyon yöntemlerine ihtiyaç duymaktadırlar.

Gerçekleştirilen tez çalışmasında beyin bölgesinde yer alan damar bölümlerinin bölütleme işlemi sağlanarak vasküler yapının incelenmesi sağlanmıştır. Bu kapsamda beyin içerisindeki damarların iki farklı şekilde segmentasyonu gerçekleştirilmiştir. İlk bölütleme işleminde beyin içerisindeki ana serebral arterlerin segmentasyonuna odaklanılmışken, ikinci yaklaşımda ise kafatası kemiğine 10 mm uzaklıktaki beyin içerisinde yer alan tüm damar bölümlerinin segmentasyonuna odaklanılmıştır. Bu nedenle her iki bölüm içinde ilk aşamada klasik görüntü işleme tabanlı teknikler vasıtasıyla beyin bölgesinde yer alan damarların bölütleme işlemi gerçekleştirilmiştir. Böylece görüntü işleme algoritmalarından faydalanılarak hızlı bir şekilde etiketlenmiş veri seti oluşturulmuştur. Oluşturulan bu veri seti ikinci aşamada derin öğrenme tabanlı UNet, ResUNet, ResUNet++ ve TransUNet gibi medikal görüntüleme alanında yaygın olarak kullanılan mimarilere uyarlanarak derin öğrenme tabanlı tekniklerin damar segmentasyon probleminde performansları karşılaştırılmıştır.

Gerçekleştirilen tez çalışması, doktorlara yardımcı bir çalışma olmasına ek olarak geliştirilen görüntü işleme algoritmaları vasıtasıyla hızlı bir şekilde etiketli veri oluşturulmasını da sağlamaktadır. Bu nedenle literatürde damarsal bölümlerin segmentasyonu ile alakalı herkesin erişimine açık herhangi bir etiketli veri seti olmadığından geliştirilen yöntem vasıtasıyla hızlı bir şekilde etiketlenmiş veri seti oluşturularak derin öğrenme tabanlı algoritmalar için transfer öğrenme işlemini de kolaylaştırmaktadır.



2. LİTERATÜR ÇALIŞMALARI

Gerçekleştirilen tez çalışması kapsamında klasik görüntü işleme tabanlı yöntemler ile derin öğrenme tabanlı yöntemlerin beraber kullanımıyla gerçekleştirilmiştir. Bu kapsamda yapılan literatür çalışmaları görüntü işleme ve derin öğrenme olmak üzere ikiye ayrılmaktadır.

2.1. Görüntü İşleme Tabanlı Literatür Çalışmaları

Beyin içerisindeki damarların oluşturduğu vasküler yapının doğru bir şekilde incelenmesi, hastalık teşhisi veya cerrahi planlama gibi birçok klinik uygulama için son derece önemlidir. Radyologlar tarafından SVH teşhisinde ve takibinde yaygın olarak MRA ve CTA gibi çeşitli anjiyografi tabanlı görüntüleme teknikleri kullanılmaktadır. Bu teknikler vasıtasıyla, hastaya ait incelenecek beyin bölgesine ait çok sayıda iki boyutlu kesit görüntüleri elde edilmektedir. Radyologlar hastalığın teşhis işleminde kesit görüntülerini incelemelerinin yanı sıra medikal görüntüleme araçları vasıtasıyla iki boyutlu kesit görüntülerini kullanarak hacimsel gösterim tekniğinden de faydalanarak üç boyutlu şekilde inceleyebilmektedir.

SVH teşhisinde hacimsel gösterim vasıtasıyla üç boyutlu damarsal yapının incelenebilmesi için medikal görüntüler içerisinde yer alan damarların doku kemik gibi istenmeyen kısımlardan ayrıştırılması gerekmektedir. MRA tabanlı medikal görüntüler incelendiğinde beyin bölgesinde yer alan damarların çevresindeki dokulara göre daha parlak olma özelliği taşımaktadır. Bu nedenle literatürde bu özellikten faydalanılarak geliştirilmiş filtreleme ve türevsel analize dayanan çeşitli teknikler vasıtasıyla damarsal yapıların belirginleştirmesine yönelik çalışmalar yer almaktadır.

Gaussian filtreleme, görüntülerdeki gürültüyü ortadan kaldırmak için kullanılan iki boyutlu konvolüsyon operatörüdür. Resim ve dijital sinyallerdeki gürültü; görüntüler üzerinde ortaya çıkan leke, bozukluk gibi istenmeyen işaretlerdir. Medikal görüntüler, görüntüleme cihazlarının doğası ve içindeki devrelerin yapısından kaynaklı çeşitli gürültü bileşenleri içermektedirler [5]. Bu tür gürültüler görüntünün kalitesinde bozulmalara neden olduğu gibi damarsal yapıların parlaklık dağılımlarında da homojen olmayan davranış göstermesine sebep olabilmektedir. Bu nedenle beyin bölgesindeki damarların bölütlenmesi işlemi için

yapılan çalışmaların ilk aşamasında Gaussian tabanlı filtreleme tekniğinden faydalanılmaktadır.

Anjiyografi tabanlı elde edilen görüntülerde yer alan damarlar, çevresindeki dokulara göre daha parlak olma özelliği taşımaktadır. Bu nedenle damarsal bölgelerin tespit işleminde, görüntüler üzerindeki kenar köşe gibi önemli noktaların tespitinde kullanılan türeve dayalı filtreler vasıtasıyla parlaklık değişiminin olduğu bölgeler ayırt edilebilmektedir. Ancak, türeve dayalı filtreler görüntü içerisindeki piksel komşuluk değerlerinin birbirleriyle değişimine dayalı olduğundan görüntü üzerindeki gürültülerden kolaylıkla etkilenebilmektedir. Bu sebeple ilk aşamada Gaussian filtreleme vasıtasıyla yumuşatma işlemi yapıp daha sonrasında çeşitli filtreler yardımıyla türev alma işlemi uygulanmaktadır. Benzer şekilde, doğrudan Gaussian filtresinin türevi alınarak da hem yumuşatma hem de parlaklık değişimlerinin algılama işlemi eş zamanlı bir şekilde gerçekleştirilebilmektedir.

Hesse matrisi, skaler değerli bir fonksiyonun ya da skaler alanın ikinci dereceden kısmı türevlerini içeren kare matris olarak adlandırılmaktadır [6]. Matematiksel olarak birinci türev herhangi bir fonksiyon grafiğinin belirli bir noktada eğimini verirken ikinci türev ise bu fonksiyonun şekli hakkında bilgi vermektedir. Hesse matrisi, görüntü üzerine uygulandığında ise tüm görüntü boyunca yerel parlaklık değişimlerinin yapısını tanımlayabilmektedir. İlerleyen aşamada bu parlaklık değişimlerini içeren her bir piksel bölgesi için öz değer ve öz vektör ayrışım işlemi uygulanarak incelenen yüzeyin geometrik bir şekilde yapısı hakkında bilgi elde edilebilmektedir.

Damar segmentasyonu alanında ilk çalışmalardan biri Sato ve arkadaşları tarafından 1997 yılında geliştirilmiştir [7]. Temelinde ikinci derece türevsel analize dayanan bu yaklaşım üç aşamadan oluşmaktadır. İlk aşamada Gaussian filtrenin ikinci derece kısmı türev bileşenlerine ayrılarak görüntü üzerine konvolüsyon işlemine tabi tutulmaktadır. İkinci aşamada ise her bir piksel değeri için hesaplanan kısmi türev değerleri bir araya getirilerek Hesse matrisini oluşturulmaktadır. Beyin bölgesi içerisinde yer alan damarlar farklı boyutlarda olabildiğinden Gaussian filtresinin ölçek ayarı yapılarak farklı boyutlardaki damarlar için farklı Hesse matrisleri elde edilebilmektedir. Son aşamada her bir piksel konumu için Hesse matrisleri üzerinden hesaplanan öz değerler arasında maksimum filtre yanıtı dikkate alınarak sonuç öz değer matrisi elde edilmektedir. Oluşturulan sonuç matrisi içerisinde yer alan öz değerlerin birbirleriyle ilişkileri incelenerek beyin bölgesindeki her bir

piksel için damar olma skoru hesaplanmaktadır.

Sato ve arkadaşları iki boyutlu kesit görüntülerinin birleştirilmesiyle oluşmuş üç boyutlu görüntü dizilerinde her bir piksel için damar olma skorunu hesaplarken üç farklı öz değer matrislerinden sadece iki tanesini kullanmaktadır. 1998 yılında Frangi ve arkadaşları ise her bir piksel için damar olma skoru hesaplanırken tüm öz değerlerin kullanılması gerektiğini ve böylece sezgisel olarak geometrik bir şekilde damarsal yapıların yorumlanabileceğinden yola çıkarak yeni bir yaklaşım geliştirmişlerdir [8]. Geliştirilen bu yaklaşım damar gibi boru şeklindeki yapıların ayrıştırılması için iki farklı öz değeri kullanırken plaka şeklindeki düz yapılarda üç farklı öz değerın birbirleriyle ilişkisinden faydalanmaktadır. Kesit görüntülerinde oluşabilecek farklı boyuttaki kontrast değişimlerinden etkilenmemek amacıyla da üç farklı öz değerin büyüklüğünü de dikkate almaktadır.

Meijering ve arkadaşları tarafından nörobiyologların molekül mekanizmasında bulunan sinir hücre uzantılarının oluşumlarını ve farklılaşmalarını tespit etmelerine yardımcı olmak için 2004 yılında yeni bir yaklaşım geliştirilmiştir [9]. Diğer çalışmalarda olduğu gibi gerçekleştirilen bu çalışmada da geliştirilen yöntem ikinci türeve dayalı olan Hesse matrisine dayanmaktadır fakat literatürden farklı olarak öz değerlerin hesaplandığı Hesse matrisi kendisi ve 90 derece rotasyonu ile toplanarak üzerinde modifiye yapılmıştır. Meijering ve arkadaşlarına göre bu durum Hesse matrisinin rotasyon matrisleri yardımıyla yönlendirilebilmesi üç boyutlu uzayda filtrenin daha geniş alandan sorumlu olmasına karşılık gelmektedir bu durum doğrudan ince uzun sinir hücre uzantılarında geliştirilen tekniğin daha fazla yanıt döndürmesini sağlamaktadır.

Jerman ve arkadaşları tarafından damarsal patolojilerin detaylı incelenmesinde filtrelerden faydalanabilmek için 2016 yılında yeni bir yaklaşım geliştirilmiştir [10]. Geçmişli yıllarda yapılan çalışmalarda anjiyografi görüntüleri üzerindeki damarların çatallanma bölgelerinde yer alan anevrizmalı bölümler, farklı ölçek ve kontrast değişikliklerinden kaynaklı geliştirilen filtrelerin uniform olmayan bir yanıt üretmesine neden olabilmektedir. Bunun temel nedeni olarak yuvarlak olan bölümlerde üretilen öz değerler birbirine oldukça yakın olmakla birlikte ince uzun yapılardaki damarlarda merkezden uzaklaştıkça parlaklık değişimlerinden kaynaklı öz değerler birbirlerinden farklı davranış sergileyebilmektedir. Bu kapsamda Jerman ve arkadaşları bu durumları göz önüne alarak yeni bir damar olma skor

fonksiyonu geliştirilmişlerdir. Böylece geliştirilen yeni teknik vasıtasıyla anevrizmal bölümlerdeki bölütleme başarısı artırılmıştır.

Anjiyografi tabanlı görüntüleme teknikleri vasıtasıyla elde edilen görüntüler üzerinde incelenecek bölgenin görüntüsünün kalitesi, sinyal gürültü oranı ve artefaktlar gibi faktörlerden doğrudan etkilenebilmektedir. Bu durum görüntüler üzerindeki damarların uniform olmayan parlaklık değişimlerine sahip olmasına neden olarak küçük ve ince damarsal yapılar üzerinde Gaussian filtreleme ve Hesse matrisi tabanlı yaklaşımların yetersiz kalmasına sebep olabilmektedir. Ayrıca, geliştirilen görüntü işleme tabanlı yöntemler, parametrik olmaları nedeniyle farklı MRA cihazlarında ve farklı hastalarda, damar dışında istenmeyen bölümlerin yanlış bir şekilde bölütleme işlemine neden olabilmektedir. Bu durum, doğru tıbbi teşhis ve tedavi planlaması açısından son derece önemli bir konudur. Bu nedenle son yıllarda derin öğrenme tabanlı yaklaşımların, görüntü işleme tabanlı tekniklerdeki zorlukları aşmak için kullanılmaya başlanmış ve daha başarılı sonuçlar üretebildiği gözlemlenmektedir.

2.2. Derin Öğrenme Tabanlı Literatür Çalışmaları

Medikal görüntüler üzerindeki damarların ayrıştırılma işlemi literatürde segmentasyon problemi olarak kabul edilmektedir. Segmentasyon, bir diğer adıyla bölümlene ya da bölütleme; bir görüntüyü farklı özelliklerin tutulduğu anlamlı bölgelere ayırma işlemi olarak tanımlanmaktadır. Derin öğrenme alanında bölütleme, semantik bölütleme ve örnek bölütleme şeklinde iki farklı kategoriye ayrılmaktadır. Semantik bölütleme problemlerinde, görüntü üzerinde yer alan objelerin içerdiği her bir piksel objenin türüne göre önceden tanımlanmış bir sınıf etiketi atanırken, örnek bölütleme de ise aynı türe ait farklı objelere farklı sınıf etiketi atanmaktadır [11].

Görüntü içerisindeki her bir piksele, türüne göre önceden tanımlanmış sınıf etiketi atmaya amaçlayan semantik bölütleme, bilgisayarlı görü alanında karşılaşılan en temel problemlerden birisidir. Semantik bölütleme problemlerinin ilk yıllarında gerçekleştirilen algoritmalar genellikle iki aşamadan oluşmaktadır. Algoritmanın ilk aşamasında görüntü işleme gibi çeşitli teknikler vasıtasıyla öz nitelikler çıkartılırken ikinci aşamasında ise bu öz nitelikler güçlendirme, rastgele orman, destek vektör makinaları gibi çeşitli tekniklerle oluşturulmuş sınıflandırıcılar vasıtasıyla bölümlenmektedir [12]. İlerleyen yıllarda

bağlamsal bilginin ve çeşitli yapısal tahmin tekniklerinin kullanılması segmentasyon anlamında önemli derecede gelişmeler sağlasa da el ile çıkarılan öz niteliklerin sınırlı oluşu geliştirilen sistemlerin performansını doğrudan etkilemiştir.

Son yıllarda teknolojiye yapılan gelişmelerin etkisiyle işlem gücü yüksek donanımların tasarlanması makine öğrenmesinin alt dalı olan derin öğrenme gibi yüksek işlem gücü gerektiren, veriden öğrenmeye dayanan algoritmaların geliştirilmesini mümkün kıldırmıştır. Özellikle örüntü tanıma problemlerinde sıklıkla kullanılan derin öğrenme tabanlı Evrişimsel Sinir Ağlarındaki(ESA) gelişmeler obje tanıma ve nesne algılama problemlerinde insan seviyesinde veya daha üstünde elde ettiği başarılar çeşitli yarışmalarda kendilerini kanıtlanmıştır.

1998 yılında Yann LeCun ve ekibi tarafından geliştirilen ilk ESA modelleri, posta numaraları ve banka çekleri üzerindeki sayıların sınıflandırılması ve tanınması için kullanılarak başarılı sonuçlar elde etmiştir [13]. Evrişimsel sinir ağlarındaki bir diğer önemli ilerleme ise Alex Krizhevsky ve arkadaşları tarafından 2012 yılında gerçekleştirilmiştir. Çalışma süresince, Alex Krizhevsky ve ekibi ESA'nın grafik işlemci birimleri üzerine yüksek düzeyde optimize edilmiş bir şekilde entegrasyonunu sağlayarak daha derin mimarilerinin eğitilmesine imkân sağlamıştır [14]. Son birkaç yılda derin öğrenme tabanlı yaklaşım olan ESA'larında yaşanan gelişmeler ile otomatik bir şekilde öz nitelik çıkartma işleminin el ile çıkarılmış öz niteliklere göre başarılı sonuçlar ürettiği çeşitli sınıflandırma yarışmalarında kanıtlanmıştır [15–18]. Bu başarılar takibinde ESA'ların sınıflandırma problemlerinden segmentasyon problemlerine de transfer edilebileceği fikrini doğurmuş ve geliştirilen modeller segmentasyon yarışmalarında da başarılarını kanıtlamışlardır [19–21].

ESA kullanarak anlamsal bölütleme konusunda ilk derin öğrenme çalışmalarından birisi Long ve arkadaşları tarafından gerçekleştirilmiştir. Çalışma içerisinde geliştirilen model sadece Evrişimli Sinir Ağlarının kaskat şeklinde birbirine bağlanmasıyla meydana geldiğinden değişken boyutta giriş görüntüsü kabul ederek giriş ile aynı boyutta çıktı görüntüsü oluşturabilmektedir. Bu çalışma ile derin ağların anlamsal bölütleme problemi için uçtan uca eğitilebileceğini kanıtlamıştır [22]. Geliştirilen bu yaklaşım popüler ve etkili olmasına rağmen gerçek zamanlı çalışmalarda yavaşlığı ve ESA'ların yerel piksel bölümlerinde çalıştığından küresel içerik bilgisinin dikkate almadığından bazı sınırlamalar içermekteydi. Liu ve arkadaşları küresel içerik bilgisini dikkate alabilmek için ParseNet

adında yeni bir model geliştirmişlerdir. ParseNet, her bir katmanda çıkarılan öz niteliklerin ortalamasını alarak, çıkarıldığı katmandaki öz niteliklerle tekrardan birleştirerek küresel içerik bilgisinin korunmasını sağlamıştır [23].

ESA sınıflandırma gibi yüksek seviyeli görevlerde oldukça iyi olsa da çeşitli boyut düşürücü katmanlar sebebiyle düşük yerleştirme özelliğine sahiptir. Bu durum geliştirilen tekniklerin objeler kenarlarında düşük kalitede segmentasyon çıktısı üretmesine neden olmaktadır. Bu kapsamda koşullu rastgele alanlar, Markov rastgele alanı gibi olasılıksal grafik modelleriyle evrişimli sinir ağlarının beraber kullanımı sağlanarak kenarlardaki yerleştirme problemlerinin önüne geçilmeye çalışılmıştır [12].

İlerleyen yıllarda gerçekleştirilen çalışmalar farklı ölçeklerdeki objelerin segmentasyon başarısını artırmak ve daha yüksek seviyedeki öz niteliklerin çıkartma işlemini sağlamak için Uzamsal Piramit Ağları ve/veya kodlayıcı-kod çözücü mimarileri geliştirilmiştir. Uzamsal Piramit Ağları içerisinde farklı boyutlarda çekirdek boyutları veya ilerleme adımı olan Evrişimli Sinir Ağlarının bir araya getirilerek farklı ölçeklerdeki objelerin segmentasyon başarısı artırılmaya çalışılmıştır [24,25]. Kodlayıcı ve kod çözücü tabanlı mimariler de ise kodlayıcı bölümünde her bir blokta öz nitelik haritasının boyutu azalırken, elde edilen öz niteliklerin seviyesi artmaktadır. Kod çözücü katmanında ise öz nitelik haritaları ters evrişim veya yukarı örnekleme metotlarıyla tekrardan eski haline getirilerek, kodlayıcı tarafında çıkarılan öz niteliklerle birleştirilmektedir. Bu sayede kenarlarda daha keskin ve başarılı segmentasyon sonuçları elde edilmiştir [26–29].

Derin öğrenme tabanlı segmentasyon modellerindeki gelişmeler ile çeşitli segmentasyon yarışmalarında elde ettikleri başarılar, medikal görüntüleme alanında da bu yöntemlerin uygulanabilirliği hakkında farkındalık oluşturmuştur. Medikal segmentasyon problemlerinin çözümündeki temel yaklaşım olan U-Net mimarisi, Ronneberger ve arkadaşları tarafından 2015 yılında ışık mikroskobu vasıtasıyla elde edilen biyomedikal görüntüler üzerindeki çeşitli hücrelerin segmentasyonunu yapmak amacıyla geliştirilerek oldukça başarılı sonuçlar elde etmiştir [27]. Bu nedenle derin öğrenme tabanlı serebral arter segmentasyonu kapsamında ilk çalışmalarından birisi de 2018 yılında Livne ve arkadaşları tarafından U-Net mimarisi kullanılarak gerçekleştirilmiştir. Yapılan çalışmada ön işlem adımı olarak z skor normalizasyon ve kafatası üzerindeki kemiklerden ayırıştırma işlemi seçilmiştir. Eğitim aşamasında ise kesit görüntüler, iki boyutlu yama şeklinde bölümlere ayrılarak daha az

parametre ile verimli bir şekilde eğitimi sağlanmıştır. Böylece bu çalışma ile büyük damarlarda yüksek bir performans sergilerken küçük damarlarda yeterli bir performans göstermektedir [30].

Hilbert ve arkadaşları damarların segmentasyon başarısını artırmak amacıyla BRAVE-NET mimarisini geliştirmiştir. Geliştirilen mimari temel olarak U-Net mimarisiyle benzerlik gösterse de, yenilik olarak ortalama havuzlama işlemi kullanılarak elde edilen bağlam bilgisi de giriş görüntüleriyle beraber mimariye verilmektedir. Ayrıca, BRAVE-NET mimarisinde eğitim işlemi sırasında, U-Net mimarisinde kullanılan iki boyutlu yamalar yerine üç boyutlu yamalar kullanılarak gerçekleştirilmiştir. Bu iyileştirmeler, özellikle küçük damarlar için yüksek segmentasyon başarısıyla sonuçlanan bir modelin geliştirilmesini olanak sağlamaktadır [31].

De Vos ve arkadaşları 2021 yılında, uçuş süresi zaman protokolünde MRA cihazları tarafından elde edilmiş görüntülerinde serebrovasküler yapıları otomatik ve doğru bir şekilde segmente etmek için derin öğrenme yöntemlerini kullanmışlardır. İki boyutlu ve üç boyutlu yama şeklindeki bölümlenmiş kesit görüntüleri üzerinde U-Net mimarisini eğitmiş olup farklı veri artırma tekniklerinin performanslarını karşılaştırmışlardır. Gerçekleştirilen çalışma doğrultusunda daha büyük yama boyutları ve Gauss bulanıklığı, döndürme ve aynalama gibi veri artırma yöntemleriyle en iyi sonuçlar elde edildiği gözlemlenmiştir [32].

Dang ve arkadaşları 2022 yılında serebral arter segmentasyon probleminde damarların küçük boyutu ve vasküler yapının karmaşıklığı tarafından ortaya çıkan zorlukları aşmak için VESSEL-CAPTCHA olarak adlandırılan derin öğrenme tabanlı yaklaşım geliştirmişlerdir. Geliştirilen bu yaklaşım, segmentasyon ağı eğitimi için ihtiyaç duyulan etiketlenmiş görüntüyü zayıf etiketleme algoritması kullanarak, alternatif etiketleme işlemi sağlanmıştır. Gerçekleştirilen çalışmanın eğitim aşamasında, birbirine sıralı olarak bağlanan iki adet U-Net mimarisinin bir araya gelerek oluşturduğu W-Net mimarisi kullanılmıştır. Önerilen yaklaşım, manuel etiketleme tekniklerine göre etiketleme süresini %77'ye kadar azaltırken, en son teknolojiye dayalı bir doğruluk elde etmektedir [33].



3. MATERYAL VE YÖNTEM

Tez çalışması kapsamında beyin görüntülerinde yer alan damar bölümlerinin segmentasyon işlemi için görüntü işleme ve derin öğrenme temelli olmak üzere iki farklı yöntem geliştirilmiştir. Bu başlık altında, tezde kullanılan teknikleri içerisinde barındıran yöntemler ile alakalı olarak genel bilgilendirmeler yapılmaktadır.

3.1. Medikal Görüntüleme Sistemleri

Tıbbi alanda, SVH tespitinde radyologlar tarafından hastalığın türüne göre üç farklı medikal görüntüleme tekniği yaygın olarak kullanılmaktadır. Bu teknikler sırasıyla Manyetik Rezonans Anjiyografi, Dijital Subtraksiyon Anjiyografi ve Bilgisayarlı Tomografi Anjiyografi şeklindedir [34]. SVH şüphesi olan hastaların tanısı aşamasında başvurulacak ilk yöntemlerden birisi görüntüleme teknolojileridir. SVH tanısı olan her hasta belirli periyotlarla anjiyografi tabanlı görüntüleme yöntemleri olan BTA ve MRA çekimleri yapılarak hastalığın takip edilmesi sağlanmaktadır.

DSA görüntüleme tekniği, vücudun tüm bölgelerinde yer alan damarlardaki daralma, genişleme, malformasyon, fistül ve benzeri hastalıkların tanısında kullanılmaktadır ve anevrizma gibi SVH tanısında altın standart olarak kabul edilmektedir [35]. DSA çekimleri öncesinde, hastaların atardamarlarına kateter vasıtasıyla kontrast madde enjekte edilerek damarların ayrıntılı bir şekilde görüntülenmesi sağlanmaktadır. Bu sebeple DSA görüntüleme tekniği invazif bir yöntemdir ve çekim süresi boyunca hastaya damardan verilen bu radyo aktif maddelerin yaydığı ışımlar görüntüleme cihazı tarafından algılanarak görüntü sinyallerine dönüştürülmektedir. Resim 3.1’de DSA cihazı ve bu cihaza ait beyin bölgesindeki çıktı görüntüsü gösterilmektedir;



Resim 3.1. DSA görüntüleme sistemi

BTA görüntüleme tekniği, vücuttaki doku veya organ gibi incelenecek bölümlerin kesit görüntüsünü oluşturan tanı yöntemidir. Bu yöntem, görüntüleme esnasında farklı açılardan alınmış iki boyutlu kesit görüntülerinin birleştirilmesiyle incelenecek yapının üç boyutlu görüntüsünü oluşturmaktadır [36]. SVH tanısında kullanılan BTA, ilaçlı ve ilaçsız olmak üzere iki farklı şekilde uygulanabilmektedir. İlaçlı görüntülemede hastaya kontrast madde enjekte edilirken, ilaçsız yöntem de herhangi bir enjeksiyon işlemi yapılmamaktadır. BTA çekimi esnasında, cihaz tarafından hastanın incelenecek doku veya organlarına kaynak olarak X ışınları yansıtılmaktadır. İncelenecek bölüm boyunca yayılan X ışınlarının zayıflamasındaki değişimler kaydedilerek görüntüye dönüştürülmektedir. Bu durum hastaların bir miktar radyasyona maruz kalmasına sebep olabilmektedir. Resim 3.2' de BTA cihazı vasıtasıyla elde edilmiş inme hastasına ait beyin kesit görüntüsü gösterilmektedir;




Resim 3.2. İnme hastasına ait BTA kesit görüntüsü

Manyetik Rezonans Görüntüleme (MRG), genellikle yumuşak dokuların görüntülenmesinde yaygın olarak kullanılan görüntüleme tekniğidir. Görüntüleme esnasında dokuların çok iyi bir şekilde anatomik görüntüsünü oluşturmasıyla beraber dokuların yapısal incelenmelerini de mümkün kıldırmaktadır. MRG cihazlarında hasta üzerinde çekilecek dokulara sabit bir manyetik alan içerisinde, radyo frekans dalgaları verilerek bu sinyaller üzerindeki değişimler incelenerek görüntü sinyalleri elde edilmektedir. Bu sebeple kullanımı sırasında hastaya herhangi bir madde enjekte edilmediğinden invazif olmayan görüntüleme tekniğidir [37].

Tez çalışması kapsamında radyasyon içermemesi, kontrastsız ya da düşük doz kontrast madde ile çekim işlemi yapılabilmesi ve hasta takip incelemelerinin birçok kez tekrar edilebilirliği nedeniyle, SVH saptanmasında invazif olmayan ve etkin bir görüntüleme yöntemi olan Manyetik Rezonans Anjiyografi tekniğinin üç boyutlu uçuş süresi çekim protokolünde ürettiği görüntüler üzerinde çalışmalar gerçekleştirilmiştir.


Üç boyutlu uçuş süresi görüntüleme tekniği sıvı akış geliştirme prensibini temel alarak geliştirilen ve beyin bölgesindeki vasküler yapının görüntülenmesini sağlayan çekim protokolüdür. Bu çekim protokolü yüksek çözünürlükte damarsal bölümlerin görüntülenmesine imkan sağlarken çekim sırasında hasta herhangi bir kontrast madde ve radyasyona maruz kalmamaktadır. Bu sebeple SVH takip işleminde yaygın olarak kullanılmaktadır. Bu tekniğe göre Manyetik Rezonans Anjiyografi görüntüleme sırasında kan akışının olmadığı veya az olduğu bölümlerde, hastaya dışarıdan verilen radyo dalgaları dokuda bulunan az sayıdaki atomları düşük seviyede uyaracağından bu bölümler görüntülere koyu renkte yansımaktadır. Kan akışının olduğu damar dokularında ise radyo dalgaları dokudaki çok sayıda bulunan atomları yüksek seviyede uyaracağından çıkış görüntüsüne daha parlak şekilde yansımaktadır [38]. Böylece vasküler yapıyı oluşturan bölümlerin incelenmesi sağlanabilmektedir. Resim 3.3’de MRA cihazı vasıtasıyla üç boyutlu uçuş süresi görüntüleme protokolünde hastaya kesit görüntüsü gösterilmektedir. Görüntü içerisinde anevrizma bölgesine ait kısım kırmızı daire ile boyanmıştır.



Resim 3.3. Anevrizma hastasına ait MRA görüntüsü

3.2. Görüntü İşleme

Görüntüler, dünya üzerindeki nesnelerin konumlandırıldığı iki boyutlu veya üç boyutlu yüzey haritaları olarak tanımlanmaktadır. Klasik görüntüleme yöntemlerinde, obje üzerine düşen ışık kaynağından yansıyan değişimler, çeşitli sensörlerin yer aldığı kameralar tarafından algılanarak objenin konum ve ışık parlaklık sinyalleri, yüzey haritaları adı verilen görüntü düzlemi üzerinde kaydedilmektedir. Medikal görüntüleme tekniklerinde ise bu görünür ışık kaynağı yerini çeşitli elektromanyetik dalgalara bırakarak incelenecek doku, organ gibi çeşitli hücreler üzerinde dalgalarda meydana gelen değişimler ve konum sinyalleri görüntü düzlemi üzerinde kaydedilerek hücrelerin işlevleri kontrol edilebilmektedir. Şekil 3.1’de temel dijital görüntü elde etme sistemi gösterilmektedir.




Şekil 3.1. Dijital görüntü elde etme sistemi [39]

Görüntüler, içerisindeki sinyallerin aldığı değer türüne göre analog ve dijital görüntü olmak üzere iki farklı gruba ayrılmaktadır. Analog görüntüler, görüntünün her bir pikselinin değerinin sürekli bir fonksiyon olarak ifade edildiği görüntülerdir. Bu nedenle, analog görüntülerde, her bir pikselin değeri sonsuz sayıda olası değere sahip olabilir. Örneğin, analog fotoğraf makineleri incelendiğinde, içerisinde ışığı filtrelerden geçirerek film üzerinde görüntü oluşturmasını sağlayan bir mekanizma kullanılmaktadır. Bu mekanizma, ışık kaynağından gelen ışığın lensler aracılığıyla odaklanmasını ve filtrelerden geçmesini sağlamaktadır. Bu filtreler, belirli dalga boylarındaki ışığı engelleyerek görüntünün oluşumunda önemli bir rol oynamaktadır. Örneğin, yeşil filtre, mavi ve kırmızı dalga boyuna sahip ışığı engellerken sadece mavi ışığın geçmesine izin vermektedir.


Analog fotoğraf makinelerinde, çekim esnasında farklı dalga boylarındaki ışık bileşenleri filtrelerden geçerek, fotoğraf makinesi içerisindeki film ile kimyasal tepkimeye girmektedir. Bu tepkimeler vasıtasıyla, bir pikselin belirli bir renginin görüntü içerisinde nasıl görüldüğü belirlenmektedir. Film üzerindeki bu kimyasal reaksiyonlar, her pikselin değerini oluşturan sürekli bir fonksiyon şeklinde kaydedilmektedir. Bu nedenle, bir analog fotoğraf makinesi ile çekilen bir fotoğrafta her pikselin içerdiği rengin değeri, bir sürekli fonksiyon vasıtasıyla ifade edilmektedir.

Dijital görüntüler ise, analog görüntülerden farklı olarak, her bir pikselin değerinin belirli bir sıklıkla örneklenerek elde edildiği görüntülerdir. Bu sıklık örnekleme periyodu olarak adlandırılmaktadır ve bu sıklık ne kadar yüksek olursa, elde edilen görüntü de keskin ve detaylı olacaktır. Dijital görüntüler, örnekleme işlemi sırasında piksel değerlerini yalnızca belirli bir değer kümesine yerleştirmektedir. Bu değer kümesi, genellikle 8 bit büyüklüğünde tam sayılardan oluşan bir kümedir. Tıbbi görüntüleme tekniklerinde ise, incelenecek dokunun daha ayrıntılı bir şekilde analiz edilmesi, teşhis doğruluğunun artırılarak görüntüleme sistemlerindeki olası hataları azaltmak amacıyla 12-16 bit gibi daha yüksek hassasiyetine sahip sayı aralığında saklanmaktadır. Şekil 3.2 üzerinde sürekli yapıdaki görüntünün belirli sıklıkla örneklenerek dijitalleştirilmesi gösterilmektedir.



Şekil 3.2. Analog – Dijital sinyal dönüşümü [39]

Dijital görüntüyü oluşturan harita üzerindeki sinyallerin depolandığı her bir nokta iki boyutlu görüntülerde piksel olarak adlandırılırken bu noktaların üç boyutlu görüntüler üzerindeki karşılığı ise voksel olarak adlandırılmaktadır. İki boyutlu görüntüler de her bir piksel elemanları bir araya gelerek satır ve sütunlardan oluşan görüntü matrisi oluşturmaktadır. Üç boyutlu görüntü matrislerinde ise satır ve sütunun yanında derinlik bilgisini içeren üçüncü bir boyut eklenmektedir. Görüntü matrisi içerisinde yer alan her bir satır veya sütun sinyalin algılandığı sensörün konumunu simgelerken içeriği ise sensör tarafından algılanan sinyalin değerini simgelemektedir. Bu kapsamda Şekil 3.3’de piksel elemanlarının bir araya gelmesiyle oluşturulmuş iki boyutlu görüntülere ait görüntü matrisi gösterilmektedir;



Şekil 3.3. İki boyutlu görüntü matris örneği [40]


Görüntü işleme, bir görüntüyü dijital bir formata dönüştürme ve üzerinde farklı işlemler gerçekleştirerek bazı yararlı bilgiler elde etme süreci olarak tanımlanmaktadır. Görüntü işleme sistemin, belirli sinyal işleme yöntemlerinin çözülmek istenilen probleme uygun olarak görüntü üzerinde uygulanmasıyla elde edilir. Bu yöntemler, görüntü işleme algoritmaları olarak adlandırılır ve önceden belirlenmiş adımlarla görüntü üzerinde işlem yaparak, gürültü azaltma, kenar tespiti, obje tanıma, renk ayarlama gibi çeşitli amaçlar için kullanılmaktadır. Günümüzde görüntü işleme teknolojisi tıpta görüntüleme ve hastalık analizi gibi pek çok alanda yaygın olarak kullanılmaktadır. Görüntü işleme teknolojisi, veri analizi ve yapay zekâ uygulamalarında da sıklıkla kullanılmaktadır ve gelecekte daha da önemli bir role sahip olması beklenmektedir.

3.2.1. Gaussian filtreleme

Görüntü filtreleme, dijital görüntü işleme alanında yaygın olarak kullanılan tekniktir. Bu teknik vasıtasıyla, görüntü içerisindeki çeşitli özellikler belirlenebildiği gibi bu özelliklerin belirginliğinin artırma işlemi de yapılabilmektedir. Görüntü filtreleme işlemleri, filtreler olarak adlandırılan çekirdek matrisleri aracılığıyla gerçekleştirilmektedir. Görüntü filtreleme işlemleri, filtreler olarak adlandırılan çekirdek matrisleri aracılığıyla uygulanmaktadır. Örneğin, görüntüyü keskinleştirmek, bulanıklığı azaltmak, kenarları vurgulamak, gürültüyü azaltmak veya renkleri değiştirmek gibi işlemler filtreleme teknikleri vasıtasıyla gerçekleştirilmektedir.

Gaussian filtreleme, doğada yer alan Gauss dağılımından esinlenilerek geliştirilmiştir ve genellikle görüntüler üzerindeki gürültüyü ortadan kaldırmak için kullanılan iki boyutlu konvolüsyon operatörüdür [39]. Bu özelliğinin yanı sıra Gaussian filtresinin ikinci türevi kullanılarak görüntüler içerisindeki blob, görüntü üzerindeki belirli bir bölgeyi oluşturan piksellerin benzer-homojen parlaklık değerine sahip olmasıyla oluşan bölge, tarzındaki yapıların bulunmasında da aktif olarak kullanılmaktadır. Aşağıda Gaussian filtresinin 2 boyutlu uzayda formülü ile birlikte gösterilmektedir;

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.1)$$




Şekil 3.4. İkinci dereceden Gaussian filtre gösterimi

Şekil 3.4’de görüleceği üzere Gaussian filtresinin kat sayıları filtre merkezinden uzaklaştıkça azalmaktadır bu durum sayesinde görüntü içerisindeki benzer piksel değerlerine sahip bölgelerde filtre yanıtının yüksek olması sağlanmaktadır. Formül içerisindeki sigma değeriyle de filtre için daha geniş veya daha dar tepe aralığı elde edilerek farklı boyuttaki unsurların tespit edilmesi sağlanabilmektedir.

Gaussian filtresinin ve konvolüsyon işleminin lineerlik özelliği, görüntü işleme uygulamalarında önemli bir rol oynamaktadır. Bu özellik vasıtasıyla, Gaussian filtresi görüntü üzerine uygulandıktan sonra türev filtreleri kullanılarak kenar ve köşe benzeri bölümlerin tespit edildiği gibi doğrudan Gaussian filtresinin türevi alındıktan sonra görüntü ile konvolüsyon işlemi yapılmasıyla da kenar köşe noktaları bulunarak benzer sonuç elde edilmektedir. Bu durum işlem gücü açısından da daha hızlı bir sonuç üretilmesini sağlamaktadır [39]. Aşağıda Gaussian filtresinin x ve y yönündeki ikinci dereceden türevlerinin toplamını içeren Laplacian of Gaussian filtresi(LoG) ve matematiksel ifadesi gösterilmektedir.

$$L(x, y) = \nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (3.2)$$

$$LoG(x, y) = \frac{1}{\pi\sigma^4} \left[1 - \frac{x^2 + y^2}{2\sigma^2} \right] e^{-\frac{x^2 + y^2}{2\sigma^2}} \quad (3.3)$$



Şekil 3.5. Laplacian of Gaussian filtre gösterimi

Giriş bölümünde bahsedildiği üzere, görüntüler üzerindeki benzer parlaklık gösteren blob tarzındaki yapıların tespit edilmesi işleminde LoG filtresi, görüntü ile konvolüsyon işlemine tabi tutulmaktadır. Filtre içerisindeki sigma parametresi ile de farklı boyutlardaki blobların tespit edilmesi gerçekleştirilmektedir.

3.2.2. Hesse matrisi


Hesse matrisi(Hessian Matrix) Alman matematikçi Otto Hesse tarafından 19. yüzyılda bulunan simetrik bir matristir. Temelde skaler değerli bir fonksiyonun ya da skaler alanın ikincide derece kısmı türevlerini içeren kare matris olarak da adlandırılmaktadır [6]. Hesse matrisi, herhangi bir fonksiyonun farklı yönlerdeki değişimlerinin miktarını gösterdiğinden çok değişkenli fonksiyonların yerel eğrilikleri hakkında da yorum yapılabilir. Şekil 3.6'da N değişkenli f fonksiyonunun Hesse Matrisi gösterilmektedir.

$$H = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{pmatrix}$$

Şekil 3.6. N boyutlu Hesse matrisi

Matematiksel olarak, bir fonksiyonun birinci türevi, belirli bir noktada eğim değerini verirken, ikinci türevi ise belirli bir noktadaki yerel ekstremum noktalarının konveks veya konkavlık durumu hakkında tanımlama yapılmasını sağlamaktadır. Geometrik olarak, bir yüzey tanımlanırken, bir fonksiyonun oluşturduğu yüzey üzerindeki herhangi bir noktanın vektörü ile bu vektöre dik şeklinde gelen normal vektör kullanılmaktadır. Bu iki vektörün noktasal çarpımı ile üç boyutlu uzayda düzlem oluşturmaktadır. Bu oluşan düzlem, bir fonksiyonun oluşturduğu yüzey ile kesişerek tek boyutlu bir iz düşüm fonksiyonu oluşturur. İz düşüm fonksiyonu vasıtasıyla istenilen noktalarda belirlediğimiz yönlerde eğrilik büyüklükleri elde edilebilmektedir. Böylece yüzeyin matematiksel bir şekilde yorumlanması sağlanmaktadır.

Yüzey üzerindeki rastgele yönlerdeki eğrilik miktarlarının bulunması tam anlamıyla yüzeyin yorumlanmasını sağlamamaktadır. Bu kapsamda Hesse matrisi, fonksiyonu oluşturan tüm yönlerde ikinci dereceden kısmi türevleri içerdiğinden her yöndeki eğrilik hakkında bilgi içermektedir. Bu kapsamda Hesse matrisi üzerinde yapılan çalışmalar da matris üzerindeki öz değer ve öz vektörler vasıtasıyla oluşan iz düşüm fonksiyonu, yüzeydeki maksimum ve minimum eğrilik yönleri ile büyüklüklerinin bulunabileceğini kanıtlanmıştır. Böylece oluşan yüzey hakkında daha anlamlı yorumlar yapılabilmektedir. Şekil 3.7’de Gaussian manzara yüzeyi üzerindeki (0, -6) noktasındaki minimum ve maksimum eğriliğe karşılık gelen öz değerler ve yönlerini ifaden eden öz vektörler gösterilmektedir [41].




Şekil 3.7. Silindirik yüzeyde öz değer ve öz vektörlerin gösterimi [41]

Yukarıdaki şekilde gösterilen Gaussian manzarası üzerinde görüleceği üzere (0,-6) noktasında eğriliğin en büyük olduğu yer olan 1. öz vektörün yönü ve büyüklüğünü mavi ok ile temsil edilirken, sarı olan ise eğriliğin en küçük olduğu ikinci öz vektörün yönü ve büyüklüğünü simgelemektedir. Hesse matrisi yardımıyla her bir noktadaki maksimum ve minimum bölgeler için bu öz değer ve öz vektörler ayrı ayrı hesaplanarak yüzey bilgisi yorumlanabilmektedir.

Matematiksel olarak, Hesse matrisi vasıtasıyla bir yüzey için öz değer ve öz vektörlerin bulunması, yüzeyin eğriliği hakkında bilgi vermektedir. Bu kapsamda Hesse matrisi ile öz değer ve öz vektörlerin beraber kullanımı, bir yüzey için aşağıdaki yorumlar yapılabilmektedir;

- İki öz değer vektörünün büyüklüğü birbirine eşit veya çok yakınsa, o bölgede oluşan eğrilik her yönde aynıdır ve herhangi bir minimum ya da maksimum bir yönelim bulunmaz. Bu durum genellikle küresel yüzeye sahip cisimlerde görülür
- İki farklı öz değer vektörü büyüklüğünden küçük olanı sıfıra çok yakınsa ve diğeri 0'dan çok büyükse, Şekil 3.10'daki örnekteki gibi bir tepe noktasında silindirik benzeri bir yapı oluşur.
- İki farklı öz değer vektörünün büyüklüğü sıfıra yakınsa, yüzeyde herhangi bir minimum veya maksimum yoktur. Bu durumun gerçekleşmesi düz bir yüzeyi temsil etmektedir. Bu durum Şekil 3.8'de gösterilmektedir.



Şekil 3.8. Düz yüzeydeki öz değer ve öz vektörlerin gösterimi [41]

Hesse matrisleri, fonksiyonlara uygulandığı gibi iki boyutlu ve üç boyutlu kesit görüntü serilerine de uygulanabilmektedir. Görüntü üzerine uygulandığında genellikle bu matris, görüntü içerisindeki her bir piksel noktası için ikinci dereceden kısmi yerel parlaklık değişimlerinin yapısını tanımlayabildiğinden, görüntü içerisinde yüzey bilgisinin yorumlanabilmesini sağlamaktadır. Şekil 3.9’da genişlik(x), yükseklik(y) ve derinlik(z) çözünürlükte “I” görüntüsü için üç boyutlu Hesse matrisi gösterilmektedir.

$$H = \begin{pmatrix} I_{xx} & I_{xy} & I_{xz} \\ I_{yx} & I_{yy} & I_{yz} \\ I_{zx} & I_{zy} & I_{zz} \end{pmatrix}$$

Şekil 3.9. Üç boyutlu görüntü matrisi

Yukarıdaki şekilde gösterilen Hesse matrisi, görüntü içerisindeki her bir vokselle için ayrı ayrı oluşturulması gerekmektedir. Örneğin, 150 adet kesit görüntüsü içeren MRA görüntüleri, her biri 512 genişlik ve 512 yükseklik boyutlarına sahip olduğunda, toplamda 39,321,600 adet vokselle içermektedir. Her bir vokselle için oluşturulacak olan Hesse matrisi, 3x3 boyutlarda matristen meydana geldiğinden toplamda 3 adet öz değer ve 3 adet öz vektör içermektedir. Bu durum görüntü içerisindeki her bir pikselin 3 farklı öz değer ve öz vektöre sahip olacağını belirttiğinden toplamda 1 17 964 800 adet öz değer ve öz vektör içermektedir. Bu öz değerlerin büyüklüğüne göre görüntü içerisindeki herhangi bir yapının geometrik olarak yorumlanması mümkündür. Çizelge 3.1’de iki veya üç boyutlu görüntülerdeki öz değer büyüklüklerine göre objelerin yorumlanabilmektedir. Çizelge içerisindeki “H” harfi yüksek, “L” harfi düşük, “N” harfi ise gürültü anlamına gelmektedir.

Çizelge 3.1. Öz değerlerin büyüklüğüne göre geometrik yapıların yorumlanması

2D	3D		orientation pattern		
λ_1	λ_2	λ_1	λ_2	λ_3	
N	N	N	N	N	noisy, no preferred direction
		L	L	H-	Plate-like structure(bright)
		L	L	H+	Plate-like structure (dark)
L	H-	L	H-	H-	Tubular structure (bright)
L	H+	L	H+	H+	Tubular structure (dark)
H-	H-	H-	H-	H-	Blob-like structure (bright)
H+	H+	H+	H+	H+	Blob-like structure (dark)

3.3. Yapay Zekâ

Yapay zekâ, bir bilgisayarın veya bilgisayar kontrollü herhangi bir makinenin, insan gibi zeki canlılara benzer şekilde çeşitli görevleri yerine getirme yeteneğinin kazandırılması şeklinde tanımlanmaktadır. Bu nedenle yapay zekâ, makinalara veya robotlara insan beyninin ve düşünme sisteminin entegre edilmiş kopyasına benzetilmektedir [42]. Günümüzde, teknolojiadaki gelişmelerin etkisiyle yüksek işlem gücüne sahip donanımların tasarlanması yapay zekâ alanındaki gelişmeleri artırmış olsa da, yapay zekâ teknolojisinin temelleri 1940-1950'li yıllarda Alan Turing'in "Makineler düşünebilir mi?" fikrini ortaya atmasına dayanmaktadır.

Yapay zekâ kavramına daha derinlemesine inceleyecek olursak, temel bir yapay zekânın kendisine öğretilen çözümleri uygulayabildiği, daha yetenekli yapay zekânın ise kendi kendine öğrenebilen sistemler olduğu bilinmektedir. Öğrenme işlemin sırasında kullanılan çeşitli algoritmalar vasıtasıyla geliştirilen sistemler de, algoritmaların problemler üzerinde oluşturduğu hatalar minimize edilecek şekilde optimizasyon işlemi yapılmaktadır. Bu bağlamda Şekil 3.10'da yapay zekâyı oluşturan alt alanlar, kendi içerisinde hiyerarşik olacak şekilde gösterilmektedir [42]. Makinelere insan benzeri kabiliyet kazandırma konusunda yapılan çalışmalar yapay zekâ gelişmeleri olarak isimlendirilirken, Makine öğrenmesi ve Derin öğrenme çalışmaları ise yapay zekânın daha alt alanlarını oluşturmaktadır.




Şekil 3.10. Yapay zekâ alt alanlarının hiyerarşik gösterimi

3.4. Makine Öğrenmesi

Makine öğrenimi ya da makine öğrenmesi, bilgisayarların veya bilgisayar kontrollü herhangi bir makinenin insan benzeri tanıma ve öğrenme görevlerini yerine getirmek amacıyla geliştirilen uygulamalar bütünü olarak tanımlanmaktadır. Makine öğrenimi, içerisinde öğrenme işlemi içerdiğinden yapay zekânın alt kümesidir. Öğrenme sürecinde kullanılan algoritmalar, veri setleri üzerindeki örneklerden bir anlam çıkararak, çıkarılan anlamları genelleştirip, farklı veriler üzerinde de uygulanmasını sağlamaktadır. Bu sayede, bilgisayarlar klasik kural tabanlı sistemler yerine, veri setindeki örnekleri genelleştirerek kendi kurallarını oluşturabilmektedir. Böylece geliştiricileri tarafından her durumu kapsayarak geliştirdikleri kurallara ihtiyaç kalmamaktadır [42].

Makine öğrenme tekniklerinin uygulanması sırasında, geliştirilen algoritmaların öğrenme sürecini takip eden ve denetleyen bir sistem olup olmaması durumuna göre Şekil 3.11’de ki gibi 3 farklı ana başlığa ayrılmaktadır. Denetimli öğrenme sırasında geliştirilen algoritmalarda, makine öğrenme algoritmalarına problemin yanı sıra problemin sonucunu içeren bilgiler de verilmektedir. Bu şekilde geliştirilen algoritmalar, girdi ve çıktı ilişkisini denetleyerek problemin öğrenilmesi amaçlanmaktadır. Denetimsiz öğrenme yönteminde ise, makineye sadece girdi bilgisi verilmektedir. Problemin sonucuna dair herhangi bir bilgi algoritmaya sağlanmadığından üretilen sonuçlar denetlenmemektedir. Böylece makineden giriş öz niteliklerini kullanarak bir örüntü oluşturulması istenmektedir. Pekiştirmeli öğrenmede yönteminde ise, algoritmadan sayısal bir ödül değerini en üst düzeye çıkartması istenir ve algoritmanın en fazla ödülü elde etmesi amaçlanır [43].




Şekil 3.11. Makine öğrenmesini oluşturan alt alanların gösterimi

3.4.1. Denetimli öğrenme

Denetimli öğrenme, öğrenme işlemi sırasında problemin içerdiği verilerin yanı sıra problemin sonucunun da öğrenme algoritmalarına verildiği öğrenme yöntemidir. Bu sebeple insan öğrenme sistemine oldukça benzerdir. Makineler, girdi verileriyle birlikte bu girdiye karşılık gelen çıktı verileri sağlanarak, probleme yönelik veri setindeki örüntünün çıkartılması istenmektedir [43].

Denetimli öğrenme konusuna örnek vermek gerekirse, kedi ve köpek görüntülerinin sınıflandırması probleminde, hangi görüntünün kedi hangi görüntünün köpek olduğu bilinmektedir. Makinenin burada yapması gereken, girdi görüntülerini kullanarak kedi ve köpeği birbirinden ayıran en önemli öz nitelikleri belirleyerek doğru çıktıya ulaşacak örüntüyü çıkartmaktır. Bu kapsamda denetimli öğrenme sırasında, model önceden etiketlenmiş veri setlerini üzerinde eğitim işlemleri gerçekleştirilerek, modelin girdileri kullanarak tahmin çıktısı üretmesi beklenmektedir. Modelin yaptığı tahminler, gerçek sonuçlarla karşılaştırarak doğru ya da yanlış olma durumuna göre çeşitli sinyal değerleri üretilmektedir. Üretilen sinyal değerlerine göre optimizasyon teknikleri vasıtasıyla modelin örüntüyü çıkartacak parametrelerinin güncellenmesini sağlanmaktadır. Bu durum Şekil 3.12’de gösterilen denetimli öğrenme blok diyagramında gösterilmektedir;




Şekil 3.12. Denetimli öğrenme blok diyagramı [44]

Denetimli öğrenme Şekil 3.12’de gösterildiği üzere problemin tipine göre sınıflandırma ve regresyon olmak üzere iki kategoriye ayrılmaktadır.

- Sınıflandırma (Clasification): Sınıflandırma problemlerinde çıktı değerleri bir kategori olarak açıklanmaktadır. Örneğin, bir önceki sayfada bahsedilen kedi köpek ayırıştırma probleminde çıktı değeri kedi veya köpek olmak üzere iki farklı kategorik değerden meydana gelmektedir. Bu kategorik değerler bilgisayar ortamında kediler 0 değeri, köpekler ise 1 değeri gibi iki farklı ayrık değer vasıtasıyla saklanmaktadır. Geliştirilen model, girdi görüntüsüne göre bu değerleri tahmin etmesi beklenmektedir. Gerçekleştirilecek tez çalışması kapsamında beyin bölgesindeki damar olan bölgeler ve damar olmayan bölgelerin bölütleme işlemi gerçekleştirilmektedir. Bölütleme problemlerinde de her bir pikselin hangi sınıfa ait olma durumu bulunduğundan bu tür problemlerde piksel seviyesinde sınıflandırma problemleri olarak adlandırılmaktadır.
- Regresyon (Regression): Regresyon problemlerinde çıktılar, sayı gibi sürekli değere sahip olduğu denetimli öğrenme çeşididir. Bu tür problemlerde geliştirilen modelin istenilen sayı çıktısına yaklaşması amaçlanmaktadır. Örnek vermek gerekirse, girdi olarak tümörlü hücrelerin görüntülerinin verildiği ve çıktı olarak da bu hücrelerin yıldaki büyüme miktarlarının tahmin edildiği uygulamalar verilebilmektedir. Görüntü işleme alanında kullanılan obje tespit algoritmaları da regresyon problemleri alanına girmektedir. Bu problemler içerisinde görüntü içerisinde yer alan objenin konumlarının bulunması işlemi gerçekleştirilmektedir.

Şekil 3.13’de sınıflandırma ve regresyon problemleri örnekleri olan bölütleme ve tespit etme işlemlerini içeren örnek gösterilmektedir;




Şekil 3.13. Medikal bölütleme ve tespit problem örneği [45]

3.4.2. Denetimsiz öğrenme

Denetimsiz öğrenme, veri seti içerisindeki örüntülerin keşfedilmesi işlemi esnasında makinanın veya bilgisayarın ürettiği çıktıların denetlenmediği öğrenme yöntemidir. Bu yöntemde, veri setindeki etiketler veya gerçek çıktı değerleri kullanılmamaktadır. Modele sadece girdiler sağlanarak, modelden çıktıları oluşturmaya beklenmektedir. Model, veri seti içerisindeki yapıları, benzerlikleri ve örüntüleri kendi kendine tanımlayarak öğrenmektedir. Bu yöntem, verilerin etiketlenmesi için zaman ve maliyet gerektiren durumlarda aktif olarak faydalanılmaktadır [43].

Denetimsiz öğrenme, genellikle veri seti içerisinde yer alan örüntülerin keşfedilmesi sırasında, kümeleme veya boyut indirgeme gibi çeşitli tekniklerden faydalanılmaktadır. Örneğin, bir müşteri veri setinde, benzer satın alma davranışları sergileyen müşterilerin gruplandırılması, denetimsiz öğrenme kullanılarak yapılabilmektedir. Ayrıca, boyut indirgeme teknikleri vasıtasıyla da özellikle büyük boyutlu veri setleri üzerinde çalışırken, ilişkilerin görsel biçimde incelenmesi amacıyla aktif olarak faydalanılmaktadır. Bu kapsamda Şekil 3.14’de denetimli öğrenme blok diyagramı gösterilmektedir.




Şekil 3.14. Denetimsiz öğrenme blok diyagramı [43]

3.5. Derin Öğrenme

Derin öğrenme, yapay zekâ alanındaki makine öğrenmesi tekniklerinin alt kümesidir ve günümüzde yüksek işlem gücüne sahip donanımların tasarlanması ve veri erişiminin kolaylaşması sayesinde yaygın bir şekilde kullanılmaktadır. Temelde derin öğrenme içerisinde çok sayıda makine öğrenmesi tekniklerinin birleşiminden meydana geldiğinden işlem gücü oldukça yüksek donanımlara ihtiyaç duymaktadır.

Makine öğrenmesi, örüntü tanıma, bilgisayarlı görü gibi alanlarda bilgisayar bilimlerinin bir alt alanıdır ve yapay zekâ teknolojilerinin alt kümesini oluşturmaktadır. Makine öğrenmesi tekniklerinde, veri seti oluşturulurken ilk aşamada veri seti üzerinde manuel ya da çeşitli algoritmalar vasıtasıyla önemli özellikleri temsil eden öz niteliklerin çıkartılması gerekmektedir. Böylece makine öğrenmesi algoritmaları, çıkarılan öz nitelikler üzerinde çeşitli matematiksel ve istatistiksel işlemler yaparak karar verme işlemini yerine getirmektedir. Derin öğrenme tekniklerinde ise yeterli veri olması halinde makine öğrenmesi uygulamalarının ilk aşamasında kullanılan öz nitelik çıkartma işlemlerinin uygulanmasına ihtiyaç duyulmamaktadır. Eğitim işlemi esnasında geri yayılım teknikleri vasıtasıyla otomatik bir şekilde öz nitelik çıkartma işlemi gerçekleşmektedir [46].

Makine öğrenmesi tekniklerinde olduğu gibi derin öğrenme teknikleri de denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme şeklinde Şekil 3.15'deki gibi üç gruba ayrılmaktadır. Gerçekleştirilecek tez çalışması kapsamında denetimli derin öğrenme teknikleri kullanıldığından ilerleyen kısımlarda bu tekniğin üzerinde durulmuştur.



Şekil 3.15. Derin öğrenmeyi oluşturan alt alanların gösterimi

3.5.1. Yapay sinir ağıları

Yapay zekânın temelini oluşturan bilgisayar veya bilgisayar kontrollü herhangi makinaya insan gibi zeki canlılara benzer şekilde çeşitli görevleri yerine getirme düşüncesi, insan beyninin öğrenme yapısının matematiksel olarak modellenmesiyle gerçekleşebileceği fikrini ortaya çıkartmıştır. Bu kapsamda, insan öğrenme yapısını temel alan yapay sinir ağıları(YSA) konusunda yapılan çalışmalar 1980 öncesi ve 1980 sonrası çalışmalar olmak üzere iki farklı ana başlık altında incelenmektedir [47].


1980 öncesi yapılan çalışmalarda ilk çalışma, Warren McCulloch ve Walter Pitts tarafından 1943 yılında elektrik devrelerini kullanarak, insan sinir sisteminden esinlenerek geliştirdikleri yapay sinir ağ hücrelerinin modellenini oluşturmaya çalışmışlardır. Gerçekleştirdikleri model ile her türlü mantıksal ifadenin formülize edilebileceğini göstermiş olsalar da o yıllarda teknolojiye gelişmeler ve şartların yetersizliği sebebiyle gerçekleştirilen bu çalışma ilgi odağı olamamıştır [47]. Frank Rosenblatt 1958 yılında ilk tek katmanlı eğitilebilen algılayıcı model olan “Perceptron” modelini gerçekleştirerek çeşitli lojik işlemleri başarı ile gerçekleştirmiş ve bu alanda çalışmalara hız kazandırmıştır [48]. 1969 yılında Marvin Minsky ve Seymour Papert tarafından o yıllarda gerçekleştirilen yapay sinir ağı çalışmalarının lineer problemlerde başarılı sonuçlar ürettiği ve lineer olmayan problemlere çözüm üretemeyeceğini öne sürmüşlerdir[49]. Bu kapsamda yapay sinir ağlarının XOR probleminin çözümünde yetersiz olduğunu göstererek yapay sinir ağıları konusunda yapılan çalışmaların yavaşlamasına neden olmuştur ve bu durum 1980 yılına kadar devam etmiştir.

1980 yılından sonraki yapılan çalışmalar ile kural tabanlı algoritmik sistemler vasıtasıyla çözülmesi zor olan problemlerin yapay sinir ağıları vasıtasıyla genelleştirileceği ve problemlere çözüm üretilebileceği anlayışı doğmuştur. Bu kapsamda teknolojinin gelişmesiyle beraber paralel programlamadaki çalışmalar ile çok katmanlı yapay sinir ağlarının üretilmesi ve geriye yayılım yönteminin kullanılmasıyla çalışmalar hız kazanarak popüler hale gelmiştir [13].

Yapay sinir ağlarının çalışmasına detaylı geçiş yapmadan önce biyolojik sinir hücresi hakkında genel bilgiye sahip olunması, yapay sinir ağı modellerinin anlaşılmasını kolaylaştırmaktadır.

Biyolojik sinir ağı hücreleri


Yapay sinir ağı modelleri, insan sinir sistemi çalışma prensibini taklit ederek geliştirilmiş matematiksel modellerden meydana gelmektedir. Bu kapsamda Yapay Sinir Ağlarının çalışmasının net bir şekilde anlaşılabilmesi için öncelikle insan sinir sisteminin anlaşılması gerekmektedir. Bu nedenle Şekil 3.19’da insan sinir hücresinin yapısı gösterilmektedir;



Şekil 3.16. Biyolojik sinir ağı hücresi [50]


Yapay sinir ağı modeller, nöron adı verilen yapay sinir hücrelerinden meydana gelmektedir. İnsan beyninde 100 milyar adet nöron olduğu tahmin edilmektedir ve nöronlar birbirleri ile bağlantı kurarak çeşitli fonksiyonları yerine getirmektedir. İnsan sinir hücresi kısaca nöronlar Şekil 3.16’da görüleceği üzere temelde Akson, Dentrit, Sinaps ve Çekirdek olmak üzere 4 ana bölümden oluşmaktadır [50]. Dentritler, dışarıdan gelen uyarı sinyallerini algılama işleminde görevli pasif elemanlardır ve hücrelerin aksonları sinaps adı verilen hücreler vasıtasıyla dentritler ile bağlantı içerisindedirler. Dentritler tarafından algılanan bu sinyaller, çekirdek vasıtasıyla aksonlarda periyodik olarak elektriksel işlem sonucu çıkış sinyali üretmektedir. Çıkış sinyalleri tekrardan akson üzerinden çeşitli kimyasal taşıyıcılar vasıtasıyla sinapslara iletilmektedir. Gelen sinyallerin eşik değerine göre çıkış hücrelerinin uyarılma ya da bastırma işlemi gerçekleşmektedir. Böylece milyonlarca sinir hücrelerinin birbirine bağlı olarak çalışması sonucunda gerçekleştirilen konuşma, düşünme vb. davranışların gerçekleşmesi sağlanmaktadır [51].

İnsan sinir sisteminde yer alan sinir hücreleri modellenerek, makine ve bilgisayarlar için kullanılabilen yapay sinir ağları oluşturulabilmektedir. Bu kapsamda Şekil 3.17'de gösterilen yapay sinir ağı, tek bir katman içerisinde yer alan bir adet nöron hücrelerini temsil etmektedir. Tıpkı insan sinir sisteminde olduğu gibi başka bir nöron ya da dışarıdan gelen sinyaller(x_0) dendritler vasıtasıyla algılanmaktadır. Algılanan sinyaller, sinapslar içerisinde yer alan çeşitli ağırlıklar ile çarpılarak hücre gövdesine iletilmektedir. Hücre gövdesinde yer alan toplama işlemi ve belirli eşik değerine göre çıktı sinyali oluşturma işlemi yapan aktivasyon fonksiyonuna maruz kalmaktadır. Üretilen çıktı yine akson benzeri bir yapı ile nöron hücrelerine ya da ilerleyen katmanlara aktararak çıktı sinyali oluşturulmaktadır [51].



Şekil 3.17. Yapay sinir hücresi [51]


Yukarıdaki şekilde yer alan yapay sinir hücrelerinin bir araya getirilmesiyle yapay sinir ağları oluşmaktadır. Yapay sinir ağları temelde giriş katmanı, gizli katmanlar ve çıktı katmanı olmak üzere 3 ana bölümden oluşmaktadır. Giriş katmanında veri seti içerisinde yer alan problemin içerdiği sinyal veya öz nitelik değerleri, gizli katmanlarda probleme yönelik önemli öz nitelikleri çıkartma işlemi yapan nöron hücre grupları ve son katmanda da anlamlı sonuç üretilmesine yarayan çıktı katmanını yer alır. Bu durum Şekil 3.18'de gösterilmektedir.



Şekil 3.18. Yapay sinir ağı katmanları [51]

Tek katmanlı yapay sinir ağı

Tek katmandan oluşan yapay sinir ağı, genellikle giriş katmanı, hesaplama işlemini yapacak bir adet nöron ve çıkış katmanı olmak üzere üç ana bölümden oluşmaktadır. Tek katmanlı algılayıcılar da, giriş vektörleri öncelikle çeşitli ağırlık değerleriyle ile çarpma işlemine tabi tutulduktan sonra genel bir toplama işlemi vasıtasıyla çıkış sinyali oluşturmaktadır. Çıkış sinyali problemin tipine göre çeşitli aktivasyon fonksiyonlarına maruz kalarak ara çıktı oluşturmaktadır. Bu ara çıktı basit eşikleme fonksiyonu vasıtasıyla ikili değer aralığına getirilerek sonuç çıktısı elde edilmektedir. Genellikle üretilen bu çıktılar iki durum içerdiğinden basit ikili sınıflandırma problemlerinde tek katmanlı yapay sinir ağı yaygın olarak kullanılmaktadır. Şekil 3.19’da tek katmanlı yapay sinir ağına ait temel blok diyagramı gösterilmektedir;




Şekil 3.19. Tek katmanlı yapay sinir ağı

Yukarıdaki şekil içerisinde yer alan tek katmanlı yapay sinir ağında x_1, x_2, x_3 gibi toplamda m adet girdi değerlerinden her biri kendisine özel w_1, w_2, w_3 gibi toplamda m adet ağırlık değerleri ile çarpılarak ara çıktı değeri oluşturmaktadır. İlerleyen kısımda bu ara çıktı değerleri çeşitli aktivasyon ve eşikleme fonksiyonuna maruz kalarak sonuç çıktısını oluşturmaktadır [46]. Bu işlemleri içeren ifadeler denklem 3.4 ve 3.5’de gösterilmektedir.

$$Z = w_0x_0 + w_1x_1 + \dots + w_mx_m \quad (3.4)$$

$$\phi(z) = \begin{cases} 1 & \text{if } z \geq 0, \\ -1 & \text{otherwise} \end{cases} \quad (3.5)$$

Şekil 3.19’da gösterilen tek katmanlı yapay sinir ağları zamanla üzerinde geliştirilen çeşitli yaklaşımlarda kullanılan aktivasyon fonksiyonlarına göre çeşitli isimlendirmeler yapılmıştır. Katman içerisinde herhangi bir aktivasyon fonksiyonu kullanılmadığında basit algılayıcı(Perceptron) olarak adlandırılırken, lineer bir aktivasyon fonksiyonu kullanıldığında uyarlanabilir doğrusal nöron(Adaptive Linear Neuron) adını almıştır. İlerleyen yıllarda çeşitli problemlerde olasılıksal çıktı almak amacıyla aktivasyon fonksiyonu olarak sigmoid kullanılmıştır ve bu modeller lojistik regresyon(Logistic Regression) adını almaktadır [43]. Bu durumlara ait genel mimariler Şekil 3.20’de gösterilmektedir;




Şekil 3.20. Tek katmanlı çeşitli yapay sinir ağları [43]

Çok katmanlı yapay sinir ağları

Çok katmanlı yapay sinir ağları, tek katmanlı yapay sinir ağları üzerinde yer alan girdi ve çıktı katman arasına gizli katman adı verilen çeşitli katmanların yerleştirilmesiyle oluşturulmuştur. Çok katmanlı algılayıcılar genellikle tek katmanlı algılayıcıların karmaşık problemlerdeki başarısını artırmak amacıyla geliştirilmiştir.


Tek katmanlı yapay sinir ağlarında girdiler sadece tek katman içerisinde yer alan ağırlık değerleriyle çarpılarak öz nitelik çıkartma işlemi gerçekleşmekteydi. Çok katmanlı yapay sinir ağlarında ise her bir gizli katman içerisinde kendisinden önce gelen öz nitelikleri çeşitli ağırlık değerleri ile çarpılıp çeşitli aktivasyon fonksiyonlarına maruz kalarak yeni öz nitelikler oluşturmaktadır. Çıkarılan bu öz nitelikler kendisinden önce gelen öz niteliklere göre daha yüksek seviyeli olmaktadır. Dolayısıyla gizli katman içerisinde yer alan katmanların artırılması yani daha derine gidilmesi öz niteliklerin seviyesini artırdığından çok katmanlı algılayıcıların başarısını doğrudan artırmaktadır. Çıktı katmanında ise gizli katmanlar vasıtasıyla çıkarılan öz nitelikler problemin tipine göre olasılıksal ya da regresyon şeklinde çıktı oluşturarak problemin çözülmesi sağlanmaktadır. Şekil 3.21’de çok katmanlı yapay sinir ağı gösterilmektedir.



Şekil 3.21. Çok katmanlı yapay sinir ağı [52]

3.5.2. Evrişimsel sinir ağları

Evrişimsel sinir ağları, diğer bir adıyla konvolüsyonel sinir ağları, derin öğrenme başlığı altında yer alan diğer bir sinir ağı çeşididir. Bu ağlar, son yıllarda bilgisayarlı görü alanında karşılaşılan çeşitli görüntü tanıma problemlerini çözmek amacıyla yaygın olarak kullanılmaktadır. Özellikle obje tanıma, obje tespiti ve obje segmentasyonu gibi yüksek seviyeli problemlerde, kural tabanlı görüntü işleme algoritmalarının yetersiz kaldığı durumlarda ESA etkili çözümler sunmaktadır. Bu sebeple tez çalışması kapsamında, SVH tespitinde kullanılacak olan damar bölütlenmesi işleminde ESA'yı temel alan mimariler kullanılmıştır. Şekil 3.22'de en temel yapıda ESA'nın birbirleriyle bağlanarak oluşturduğu sınıflandırma mimarisi gözükmemektedir. Geliştirilen bu mimari, giriş görüntüleri üzerinden kedi köpek gibi birçok sınıfın ayrıştırma işlemini gerçekleştirebilmektedir.



Şekil 3.22. Evrişimli sinir ağları mimarisi [53]


ESA, canlıların görsel korteksinin öğrenme mantığının örneklenmesi temeline dayanmaktadır. Hubel ve Wiesel hayvan beyinleri üzerinde yaptıkları çeşitli deneylerde görsel korteks üzerine düşürdükleri görüntüler de korteks üzerinde yer alan algılayıcıların birbirinden farklı sinyaller ürettiğini gözlemlemiştir. İlerleyen yıllarda yapılan çeşitli çalışmalarda da görsel korteks üzerindeki bazı nöronların görüntü içerisinde yer alan dikey kenarlara maruz kaldığında sinyal üretirken diğer nöronların bir kısmının da yatay veya diyagonal kenarları tespit ettiğinde sinyal ürettiği gözlemlemiştir. Böylece üretilen farklı seviyedeki sinyaller beynin karmaşık görüntü merkezlerine iletilerek görüntü oluşturma işlemi gerçekleşmektedir [54]. Evrişimli Sinir Ağları da bu çalışma prensibini referans alarak geliştirilmiş olup, görüntüler üzerinde yer alan çeşitli kenar ve köşe gibi problemin türüne göre önemli noktalar da sinyal üretme işlemi gerçekleşmektedir.

Evrişimli sinir ağları, YSA'nın görüntü işleme problemlerine uygulanabilirliğini artırmak amacıyla özelleştirilmesiyle oluşturulmuştur. YSA, temelde girdi katmanları üzerinde yer alan her bir girdi vektör değerleri için ağırlık matrisi oluşturmaktadır. Görüntü işleme tabanlı problemlerde, giriş vektörleri görüntünün genişlik yükseklik gibi çözünürlük değerine bağlı olduğundan, YSA tabanlı mimarilerin kullanılması her bir piksel için ağırlık değerinin oluşturulmasına neden olmaktadır. Bu konuya matematiksel biçimde örnek vermek gerekirse; 512×512 çözünürlük boyutunda 3 kanallı bir görüntü, toplamda 786 432 adet pikselden meydana gelmektedir. İlk katman içerisinde toplam 10 adet nörondan oluşan bir YSA mimarisinde, bu boyuttaki giriş için yaklaşık 7 860 432 adet ağırlık değerine ihtiyaç duyulmaktadır. Bu durum işlem yükünün artmasına sebep olduğu gibi, YSA'nın yapısından kaynaklı giriş vektörü içerisinde yer alan değerlerin birbiriyle ilişkisinin göz ardı etmesine de neden olmaktadır. Bu durum görüntü gibi her bir pikselin kendisine komşu piksel ile ilişkisi olan görevlerde uygulanabilirlik açısından problem oluşturmaktadır. Bu gibi sebeplerden dolayı ESA geliştirilmiştir.

Geçmişli yıllarda bilgisayarlı görü alanında obje tanıma, tespit ve bölütleme gibi çeşitli problemler üzerinde, uzmanlar tarafından probleme yönelik filtre tasarımı yapılarak görüntüler üzerinde yer alan önemli öz niteliklerin çıkartılması gerekmektedir. Çıkartılan öz nitelikler ilerleyen aşamada, çeşitli makine öğrenmesi veya klasik kural tabanlı algoritmalar kullanılarak ilgili probleme yönelik çözüm üretilmekteydi [12]. Evrişimli Sinir Ağları ise uzmanlar tarafından probleme yönelik manuel ya da çeşitli algoritmalar vasıtasıyla elde edilen öz niteliklerin, geri yayılım algoritması ile otomatik bir şekilde çıkartılmasını sağlamaktadır. Yapay sinir ağlarında, her bir katman içerisinde yer alan ağırlık değerleri, giriş vektörü ile lineer bir şekilde yapılan matris çarpım işlemi vasıtasıyla yüksek seviyeli öz nitelikler elde edilmektedir. Evrişimli Sinir Ağlarında ise her bir katman içerisinde yer alan ağırlık değerleri filtre biçiminde tasarlanarak giriş vektörleri ile konvolüsyon işlemine maruz kalmaktadır. Bu sayede, görüntü üzerinde her bir piksel, katman içerisinde yer alan benzer filtre değerleriyle konvolüsyon işlemine tabi tutulmaktadır. Böylece filtreler içerisindeki ağırlıkların giriş görüntüsü üzerinde paylaşılma durumu söz konusu olmaktadır. Bu nedenle, $224 \times 224 \times 3$ şeklinde bir giriş için 10 adet 3×3 boyutlarda filtre kullanılması toplamda 270 adet parametre ihtiyacı oluşturmaktadır. Bu durum, hem işlem yükünün azaltılmasını hem de resim gibi piksellerin birbirleriyle ilişkili olduğu problemlerde komşuluk ilişkilerinden faydalanılmasını sağlamaktadır [55].

Evrişim katmanı

Konvolüsyon ya da diğer bir adıyla evrişim işlemi, mühendislik, olasılık, istatistik, fizik ve sinyal işleme gibi birçok farklı alanda uzun yıllardır bilinen ve yaygın olarak kullanılan matematiksel işlemidir. Genellikle bu işlem bir fonksiyonun şeklinin başka bir fonksiyon tarafından nasıl modifiye edildiğini gösterdiğinden bu işlem vasıtasıyla, birim dürtü yanıtı, $h(t)$, bilinen lineer bir sistemin, herhangi bir giriş işaretine, $x(t)$, karşılık üreteceği çıkış sinyalini, $y(t)$, zaman domaininde bulunmasında kullanılmaktadır [56]. Literatürde konvolüsyon işlemi gösteriminde yaygın olarak “*” sembolü kullanılmaktadır. Şekil 3.26’da lineer bir sisteme uygulanan konvolüsyon işleminin blok diyagramı ile bu işlemin ayrık domainde oluşturduğu matematiksel eşitlikler gösterilmektedir;



Şekil 3.23. Konvolüsyon işlemi blok gösterimi

$$y[t] = x[t] * h[t] \quad (3.6)$$

$$y[n] = \sum_{k=-\infty}^{k=+\infty} x[n] \cdot h[n - k] \quad (3.7)$$

Görüntü işleme alanında, nesne tanıma, sınıflandırma ve tespit gibi problemler için yaygın olarak kullanılan derin öğrenme tabanlı ESA mimarilerinin, evrişim katmanlarında temel olarak konvolüsyon işlemi kullanılmaktadır. Bu işlem, tek boyutlu ayrık domainde uygulanan konvolüsyon işleminin özelleştirilmesiyle görüntü üzerinde gerçekleştirilmektedir. Genellikle bu özelleştirme işlemi iki boyutlu veya üç boyutlu girdi görüntülerine bağlı olarak Eşitlik 3.7 üzerine boyut ekleme işlemi vasıtasıyla yapılmaktadır. Bu sayede, görüntüdeki özelliklerin çıkarılması ve nesne tanıma, sınıflandırma ve tespit gibi problemlerin çözümleri için gerekli olan öz nitelik bilgilerinin otomatik olarak elde edilmesi, geri yayılım algoritmasıyla beraber kullanılarak mümkün olmaktadır.

Görüntüler üzerinde uygulanan konvolüsyon işleminin daha detaylı incelemesi Şekil 3.24 üzerinde gösterilmektedir. Şekil üzerinde görüleceği üzere konvolüsyon işleminin ilk aşamasında, H ile gösterilen çekirdek matrisi 180 derece döndürüldükten sonra görüntü üzerine yerleştirilmektedir. İkinci aşamada ise görüntü üzerine yerleştirilen filtre matrisinin içerisindeki değerlerin görüntü üzerinde karşılık geldiği piksel değerleriyle önce çarpma işlemi ardından toplama işlemi yapılarak yeni piksel değeri elde edilmektedir. Üçüncü aşamada elde edilen yeni piksel değeri, filtrenin yerleştiği görüntüdeki merkez değeri ile değiştirilmektedir. Son aşamada ise ilk üç aşamada yapılan bu işlemler, çekirdek matrisinin tüm görüntü boyunca belirlenen adım sayıları ile kaydırılmasıyla tekrar etmektedir. Bu kapsamda Eşitlik 3.8’de görüntüler üzerinde uygulanan iki boyutlu konvolüsyon işlemi gösterilmektedir. Burada girdi matrisi yani giriş görüntüsü f ile simgelenirken, görüntü içerisindeki piksel konumları “k” ve “l” ile gösterilmektedir. H ise filtre matrisini simgelemektedir, “i” ve “j” değerleri ise filtre matrisi içerisindeki elemanların ötelenmelerinde kullanılmaktadır. İlk üç aşamada bahsedilen işlemlerin açık hali aşağıda gösterilmektedir;

$$f * h = \sum_k \sum_l f(k, l) h(i - k, j - l) \quad (3.8)$$

$$f = \begin{bmatrix} f_1 & f_2 & f_3 \\ f_4 & f_5 & f_6 \\ f_7 & f_8 & f_9 \end{bmatrix}, \quad h = \begin{bmatrix} h_1 & h_2 & h_3 \\ h_4 & h_5 & h_6 \\ h_7 & h_8 & h_9 \end{bmatrix}$$

$$f * h = f_1 h_9 + f_2 h_8 + f_3 h_7 + f_4 h_4 + f_5 h_5 + f_6 h_6 + f_7 h_3 + f_8 h_2 + f_9 h_1 \quad (3.9)$$

Görüntü Matrisi						Çıktı Matrisi					
0	0	0	0	0	0	23					
0	30	55	80	105	130						
0	42	34	26	18	10						
0	89	23	43	109	175						
0	102	44	14	72	130						
0	55	45	35	25	15						
0	23	75	127	179	231						


Çekirdek Matrisi		
0	-1	0
-1	4	-1
0	-1	0

Şekil 3.24. Konvolüsyon işlem gösterimi

Evrişimsel sinir ağları ismini ne kadar konvolüsyon işleminden almış olsa da Pytorch, Tensorflow gibi çeşitli derin öğrenme kütüphanelerinde, hız optimizasyonu açısından konvolüsyon işlemi yerine çapraz korelasyon işlemi tercih edilmektedir. Evrişim işleminde, görüntü üzerine yerleştirilen filtre ile görüntü elemanları arasında çarpım işlemi yapılmadan önce filtre 180 derece döndürülmektedir. Çapraz korelasyon tekniğinde ise doğrudan görüntü üzerine yerleştirilen filtre ile karşılık geldiği piksel elemanları doğrudan çarpılmaktadır. Bu durum teoride öğrenme işlemi sırasında, başarı açısından herhangi bir sonuç değişikliği yapmamaktadır. Bunun temel nedeni evrişim tekniği ile öğrenilmiş filtreler, çapraz doğrulama ile öğrenilmiş filtrelerin döndürülmüş halidir. Bu kapsamda, çapraz korelasyon işlemine ait matematiksel ifade Eşitlik 3.10'da gösterilmektedir;

$$(I \otimes F)_{m,n} = \sum_{j=-\infty}^{j=+\infty} \sum_{i=-\infty}^{i=+\infty} I[i,j]F[m+i,n+j] \quad (3.10)$$


Evrişimsel sinir ağları içerisinde çapraz korelasyon işlemi kullanılmış olsa da literatürde bu işlemi anlatmak amacıyla yaygın olarak evrişim terimi kullanılmaktadır. Bu nedenle gerçekleştirilen tez çalışma kapsamında da çapraz doğrulama işlemi evrişim işlemi olarak adlandırılacaktır. Şekil 3.25'de 5x5 boyutundaki giriş görüntüsünün 3x3 boyutundaki filtre ile evrişim işlemindeki her bir adım gösterilmektedir.



Şekil 3.25. Evrişimsel sinir ağlarında evrişim işlemi

Havuzlama ve ortalama katmanları


Havuzlama katmanları(Pooling Layers). Literatürde derin öğrenme alanında yaygın olarak maksimum havuzlama ve ortalama havuzlama olmak üzere iki temel havuzlama katmanı yer almaktadır. Maksimum havuzlama işleminde belirlenen filtre boyutu belirli adım aralığında görüntü içerisinde kaydırılarak pencere içerisinde kalan değerlerden maksimum yanıtı veren ilgili pencereyi temsil eden değer çıktı olarak kullanılmaktadır. Ortalama havuzlama katmanı da maksimum havuzlama katmanına oldukça benzer olmakla birlikte birbirini ayıran en temel özellik ise pencere içerisindeki değerlerin ortalaması alınarak pencereyi temsil eden değer belirlenmektedir [57]. Havuzlama katmanları genellikle ESA katmanlarının ardından oluşan öz nitelik haritasının boyutunu azaltarak hesaplama işleminin maliyetini düşürdüğü gibi görüntüler içerisinde yer alan öteleme hareketinden etkilenmeyen öz nitelik haritalarının oluşmasını sağlamaktadır. Şekil 3.26'da maksimum havuzlama katmanı ve ortalama havuzlama katmanının yaptığı işlemler gösterilmektedir.



Şekil 3.26. Maksimum ve ortalama havuzlama katman [57]

Sıkıştır ve uyarma ağ katmanı


Sıkıştır ve uyarma ağ katmanı(Squeeze and Excitation Network), Jie Hu ve arkadaşları tarafından 2018 yılında derin öğrenme algoritmalarının ürettiği öz nitelik haritalarının temsil güçlerini artırmak amacıyla geliştirilmiştir. Bu ağlar temelde sıkıştırma, uyarma ve örnekleme olmak üzere üç ana parçadan meydana gelmektedir. Sıkıştırma aşamasında giriş görüntüsü veya öz nitelik haritası küresel havuzlama katmanından geçirilmektedir. Böylece giriş görüntüsü veya öz nitelik haritası uzamsal çözünürlüklerden arındırılarak kanal sayısı kadar bilgi içermektedir. Uyarma bölümünde ise YSA veya ESA ile birlikte aktivasyon fonksiyonları kullanılarak kanalların birbirleriyle olan ilişkileri çıkartılmaktadır. Bu sayede her bir kanal için önem değerleri belirlenmiş olmaktadır. Bu değerler son aşama olan ölçekleme aşamasında tekrardan giriş görüntüsü veya öz nitelik haritası ile çarpılarak kanalların içerdiği önemli bilgiler korunurken önemsiz bilgiler ise bastırılmaktadır [58]. Şekil 3.27’de sıkıştır ve uyarma bloğu gösterilmektedir.



Şekil 3.27. Sıkıştır ve uyarma bloğu [59]

Atrous uzamsal piramit havuzlama katmanı

Atrous uzamsal piramit havuzlama katmanı(Atrous Spatial Pyramid Pooling), 2016 yılında Liang-Chieh Chen ve arkadaşları tarafından segmentasyon mimarilerinin farklı ölçeklerdeki objelerden etkilenme probleminin önüne geçebilmek amacıyla geliştirilmiştir. Bu katman içerisinde giriş görüntülerine veya öz nitelik haritalarına farklı genişleme değerlerine sahip ESA uygulanarak filtrelerin görüş alanları artırılmaktadır. Böylece geniş bağlam bilgisine ulaşarak, farklı ölçeklerdeki objelerin tespitinde kullanılabilir yüksek seviyeli öznitelikleri çıkarılmaktadır. Katman çıkışında bu öz nitelikler tekrardan birleştirilerek, ESA uygulanarak kompakt yapıda öz niteliklerin çıkartılması sağlanmaktadır. Bu sayede kenar köşe gibi bölümlerde segmentasyon çıktılarındaki yerleştirme problemi çözülerek daha başarılı çıktılar elde edilmektedir [12]. Şekil 3.28’de Atrous Uzamsal Piramit Havuzlama bloğu gösterilmektedir.




Şekil 3.28. Atrous uzamsal piramit havuzlama katmanı [12]

3.5.3. Yinelemeli sinir ağıları

Yinelemeli sinir ağıları(Recurrent Neural Network), derin öğrenme alanında kullanılan yapay sinir ağlarının özelleştirilmesiyle oluşturulmuştur. Temelde yapay sinir ağıları, girdi vektörleri içerisindeki bilgiler arasında sıralı bir ilişki içermezken, yinelemeli sinir ağıları girdi bilgileri içerisindeki zamansal bağımlılıkları modellemek için geliştirilmiştir. Bu kapsamda yinelemeli sinir ağıları, doğal dil işleme, konuşma tanıma, zaman serisi verileri gibi giriş bilgilerinin birbirleriyle sıralı ilişkisi olan problemlerde yaygın olarak kullanılmaktadırlar.

Yinelemeli sinir ağı mimarileri, temelde çok sayıda tekrar eden YSA hücrelerinden meydana gelmektedir. Bu hücreler, her bir adımda önceki adımdan elde edilen bilgiyi hafızalarında tutarlar ve bu bilgiyi mevcut girdi verileriyle birleştirerek daha doğru bir çıktı bilgisi üretmektedir. Yinelemeli sinir ağı mimarilerinde yer alan her bir hücrede aynı ağırlık değerlerine sahip YSA tekrarlı olarak kullanılmaktadır. Bu durum eğitim işlemi esnasında ağırlık paylaşım durumunu sağlayarak kullanılacak parametre sayısını azaltmaktadır. Bu kapsamda geleneksel yinelemeli sinir ağı mimarisi, Şekil 3.29'da gösterilmiştir. Mimari içerisinde, giriş vektörleri “x” ile temsil edilirken, her bir hücrede hesaplanan aktivasyon değerleri “a” harfi ile ifade edilmektedir. Bu yapıda, her hücre, önceki adımdan gelen aktivasyon değerleri ile mevcut girdi vektörlerini birleştirerek yeni bir aktivasyon değeri üretmektedir. Bu aktivasyon değeri, hem bir sonraki adımın hesaplamalarında kullanılırken, hem de çıktı değeri olarak kullanılabilir [60].




Şekil 3.29. Geleneksel yinelemeli sinir ağı mimarisi [60]

Yinelemeli sinir ağı mimarilerine daha detaylı inceleyecek olursak, Şekil 3.30’da mimari içerisinde her bir hücrede kullanılan bileşenler ile bu bileşenlerden çıkış sinyali üretmede faydalanılan matematiksel ifadeler gösterilmektedir. Denklemler üzerinde açıkça görüleceği üzere, t anındaki giriş vektörü ve kendisinden önceki hücreden ” $t-1$ ” anında gelen aktivasyon sinyalleri YSA hücrelerinin içerdiği ağırlık ve bias değerleriyle işlenerek aktivasyon çıktı sinyali oluşturmaktadır. Bu sinyal ise son aşamada üçüncü bir YSA hücresinin içerdiği ağırlık ve bias değerleriyle işlenerek çıktı sinyali oluşturmaktadır.

$$a^{(t)} = g_1(W_{aa}a^{(t-1)} + W_{ax}x^{(t)} + b_a) \quad (3.11)$$

$$y^{(t)} = g_2(W_{ya}a^{(t)} + b_y) \quad (3.12)$$




Şekil 3.30. Yinelemeli sinir ağı hücre gösterimi [60]

Yinelemeli sinir ağı temelli çalışmalar incelendiğinde, dil işleme problemleri gibi uzun sıralı girdi verileri içeren alanlarda geri yayılım algoritmasında kullanılan türev değerlerinin yok olması ve sadece geçmişteki bilgidен yararlanılması gibi problemler ortaya çıkmaktadır. Bu durum, gelecekteki bilginin kullanılamaması ve dolayısıyla dil işleme gibi sıralı bilgi içeren problemlerde düşük başarılı sonuçların üretilmesine neden olabilmektedir [61]. Bu kapsamda hücreler içerisindeki yapılan geliştirmeler sonucunda yeni yaklaşımlar elde edilmiştir.

Geçitli tekrarlayan üniteler

Yinelemeli sinir ağı temelli çalışmalar incelendiğinde, geri yayılım algoritması vasıtasıyla ağırlık değerlerinin güncellenmesi için kullanılacak olan türev değerlerinin uzun sıralı gelen cümlelerde yok olması ve sadece geçmişteki bilgiden yararlanılması sebebiyle, dil işleme problemlerinde iyi sonuçlar üretmek zor olabilmektedir. Bunun temel nedeni türev değerleri güncelleme işlemi esnasında kullanıldığında ağırlık değerlerinin kaybolmasına yol açarak etkili bir şekilde eğitim işlemini mümkün kıldırılmamaktadır. Bu problemin önüne geçilmesi amacıyla literatürde yaygın olarak kullanılan geçitli tekrarlayan ünite(Gated Recurrent Unit) geliştirilmiştir [62].

Geçitli tekrarlayan üniteler(GRU) temelde yinelemeli sinir ağı hücrelerinin özelleştirilmesiyle oluşturulmuştur. Bu özelleştirme işleminde, güncelleme ve uygunluk adı verilen yeni iki adet kapı kullanılmaktadır. Bu kapılar vasıtasıyla t-1 anında gelen aktivasyon bilgisinin, t anında gelen giriş bilgisi ile ilişkisi uygunluk kapısı vasıtasıyla bulunurken, güncelleme kapısı vasıtasıyla da geçmişten gelen gizli durum bilgilerinin ağırlıkları belirlenmektedir. Bu sayede geri yayılım algoritması sırasında elde edilen türev değerlerinin yok olması önlenmektedir. Bu kapsamda Şekil 3.31’de geçitli tekrarlayan birim hücresi gösterilmektedir [60].




Şekil 3.31. Geçitli tekrarlayan ünite gösterimi [60]

Uzun kısa vadeli bellek

Uzun kısa vadeli bellek(Long Short Term Memory) hücreleri, uzun ve kısa dönem bellekleri bir arada kullanarak uzun dönem bağımlılıkları modellemek için tasarlanmış bir yinelemeli sinir ağı hücresidir. Uzun kısa süreli bellek(LSTM) hücreleri tıpkı GRU hücresinde olduğu gibi, girdiler, aktivasyon sinyalleri ve gizli durum bilgilerini kontrol eden kapı mekanizmalarını kullanarak, hafızadan uzun dönem boyunca faydalanabilmektedir. Bu sayede, zaman içerisindeki giriş sinyalleri arasındaki bağımlılıklar daha iyi modellenerek daha anlamlı sonuçlar elde edilmektedir.

LSTM hücreleri temelde GRU hücrelerine oldukça benzer olmakla birlikte, unutma ve çıkış kapısı olmak üzere iki adet yeni kapı eklenmiş yeni sürümüdür. Unutma kapısı vasıtasıyla, “t-1” anında geçmişten gelen gizli durum bilgilerinden hangi bilginin unutulacağı belirlenmektedir. Çıkış kapısı vasıtasıyla ise hafıza hücrelerinde yer alan bilgilerin ne kadarının son çıktıya etki edeceği kontrol edilebilmektedir [60]. Bu kapsamda Şekil 3.32’de LSTM hücresi gösterilmektedir;




Şekil 3.32. Uzun kısa süreli bellek hücre gösterimi [60]

Dikkat mekanizmaları

LSTM veya GRU hücreleri içerisine yerleştirilen hafıza bellek hücreleri, her ne kadar uzun sıralı girişe sahip problemlerde türev değerlerinin yok olmasının önüne geçmiş olsa da, bu tarz mimariler çeviri gibi dil modelleme problemlerinde düşük başarı skoru ile sonuç üretmektedir. Bu durumun temel nedeni, uzun cümleler içerisinde yer alan kelimelerin birbirleriyle olan ilişkilerinin çıkartılmasında LSTM veya GRU hücreleri yetersiz kalabilmektedir. Bu mimariler, yalnızca kendisinden bir adım önce veya bir adım sonrasındaki aktivasyon veya gizli durum bilgilerinden belirli ağırlık oranında faydalanabilmektedir. Kelimeler arasındaki uzaklık arttıkça bu faydalanma oranı azalır ve özellikle çeviri gibi uzun cümlelerde düşük başarı skorlarının üretilmesin neden olmaktadır.

LSTM mimarilerinin çeviri gibi problemlerde yetersiz kalmasının engellemek amacıyla ilerleyen yıllarda LSTM blokları içerisinde yer alan gizli durum bilgilerinin birbirleriyle ilişkilerinin çıkartılması amacıyla dikkat mekanizması(Attention Mechanism) adı verilen bloklar geliştirilmiştir. Bu bloklar vasıtasıyla, her bir giriş adımında çıkartılan gizli durum bilgilerinden sıra bağımsız bir şekilde sıralı tüm çıkış vektörleri faydalanabilmektedir. Şekil 3.33'de “y” harfi sıralı çıkış kelimelerini simgelerken “h” harfi ise sıralı gizli katman bilgilerini içermektedir. Softmax fonksiyonu vasıtasıyla her bir gizli katman bilgisinin ağırlığı belirlenerek çıkış vektöründe tüm bilgilerden faydalanılması sağlanmaktadır. Bu kapsamda elde edilen bu yaklaşım, Bahdanau ve arkadaşları tarafından geliştirilmiş olup, ekleme tarzında dikkat mekanizması(Additive Style Attention Mechanism) olarak adlandırılmaktadır [63].



Şekil 3.33. Ekleme tarzında dikkat mekanizması blok gösterimi [64]

Şekil 3.33’de gösterilen, eklemeli dikkat mekanizması bloğu, sıralı tüm kodlayıcı gizli durum bilgileri ile çıkışa karşılık gelen kod çözücü gizli durum bilgilerini, YSA vasıtasıyla kullanarak skor değerleri oluşturmaktadır. Bu değer ilerleyen aşamada, softmax fonksiyonundan yararlanılarak, çıkışa karşılık gelen kod çözücü ile kodlayıcı kısımdaki gizli durum bilgilerinin birbirleriyle arasındaki ilişkiyi veren kat sayılar hesaplanmaktadır. Bu katsayılar doğrudan içerik vektörünün(Context Vector) hesabında kullanılmaktadır. Son aşamada içerik vektörü ve kod çözücü gizli katman bilgisi tekrardan kullanılarak çıkış kelime vektörü oluşturulmaktadır. Bu işlemleri içeren matematiksel ifadeler aşağıda gösterilmektedir. Eşitlikler içerisindeki, “s” harfi bir önceki kod çözücü gizli durum bilgisini temsil ederken, “h” harfi ise kodlayıcı kısmındaki gizli durum bilgisini temsil etmektedir. Kelimelerin birbirleriyle ilişki kat sayılarını çıkarmada kullanılan Softmax fonksiyonu ise Eşitlik 3.14’de gösterilmektedir.

$$Score(s_{t-1}, h_i) = v_a^T \tanh(W_1 h_i + W_2 s_j) \quad (3.13)$$

$$a_{t,i} = \frac{e^{(Score(s_{t-1}, h_i))}}{\sum_{i'=-1}^n e^{(Score(s_{t-1}, h_{i'}))}} \quad (3.14)$$


$$c_t = \sum_i a_{t,i} h_i \quad (3.15)$$

İlerleyen yıllarda yapılan çalışmalarda Bahdanau ve arkadaşları tarafından geliştirilen eklemeli dikkat mekanizma bloğunun uzun cümlelerde softmax aktivasyon fonksiyonundan kaynaklı doyuma gittiği ve içerisinde yer alan yapay sinir ağlarından kaynaklı hesaplama maliyeti ürettiği gözlemlenmiştir. Bu kapsamda Luong ve arkadaşları tarafından nokta çarpım dikkat mekanizma(Dot Product Attention) bloğu geliştirilmiştir. Geliştirilen yeni yaklaşım, kodlayıcı ve kod çözücü kısımlarında üretilen gizli durum bilgilerinin doğrudan çarpılarak oluşturduğu çıktı vektörünün Softmax aktivasyon fonksiyonu uygulaması yapılarak, ağırlık katsayılarının hesaplanmasını sağlamaktadır [65]. Bahdanau ve arkadaşlarında olduğu gibi Luong ve arkadaşları tarafından da başarıyı artırmak amacıyla YSA kullandıkları çeşitli denklem formları da yer almaktadır. Literatürde bu formlardan en çok kullanılanı nokta çarpım dikkat mekanizması olarak adlandırılmaktadır ve doğrudan kod çözücü gizli durum bilgileri ile kodlayıcı gizli durum bilgilerinin çarpılması ile elde edilmektedir.

Dönüştürücü mekanizmaları

Dikkat mekanizmaları, çeviri gibi problemlerde oldukça başarılı olmasına rağmen, kelime içerisindeki özelliklerin çıkarılması konusunda bazen yetersiz kalabilmektedir. Bu nedenle, 2017 yılında Vaswani ve arkadaşları tarafından, dönüştürücüler(Transformers) adı verilen blok mimarileri geliştirilmiştir. Dönüştürücü blokları içerisinde kullanılan yapılar, veri tabanı sistemlerinden etkilenecek isimlendirilmiştir. Örneğin, Youtube’da her bir video için başlık gibi anahtar(Key) kelimeler içermektedir. Kullanıcıların arama yaparken, izlemek istediği videoları bulması ise sorgu(Query) durumunu simgelemektedir. Arama sonuçlarına bağlı olarak önerilen videolar ise çıktı değerlerini(Value) simgelemektedir. Bu nedenle dönüştürücü mimarilerinde, giriş vektörleri üç farklı yapay sinir ağından geçirilir ve her bir sinir ağının çıktısı, "key", "query" ve "value" olmak üzere üç farklı gömme vektörü(Embedding Vector) elde edilmektedir. Bu vektörlerden “key” ve “query”, dikkat mekanizması vasıtasıyla, sıralı giriş cümlesindeki kelimeler arasındaki ilişkiyi veren kat sayılarının hesaplanması için kullanılır ve çıkış “value” ile ilişkilendirilerek çıkış vektörü oluşturulmaktadır [66]. Bu duruma ait ikinci kelime ile alakalı dönüştürücü çıkış vektörünün matematiksel ifadesi Eşitlik 3.16’da verilmekte olup ve Şekil 3.34’de gösterilmektedir.


$$A(q_2, K, V) = \sum_{i=1}^T \frac{e(q_2 k_i^T)}{\sum_j e(q_2 k_j^T)} \times v_i \quad (3.16)$$



Şekil 3.34. Nokta çarpım dikkat mekanizması blok gösterimi [64]

Dönüştürücü blokları detaylı incelendiğinde, temelini çok sayıda nokta çarpım dikkat mekanizması bloklarının bir araya gelerek oluşturduğu çoklu kafa dikkat (Multi Head Attention) hücrelerinden meydana gelmektedir. Burada dikkat edilmesi gereken kısım “query” ve “key” öz nitelik vektörlerinin nokta çarpım dikkat mekanizması sonuçları incelendiğinde, Softmax aktivasyon fonksiyonunun doyuma gittiği gözlemlenmiştir. Bu durumun önüne geçebilmek amacıyla ölçeklendirme işlemi yapılmış ve bu sebeple ölçeklendirilmiş nokta çarpım dikkat mekanizması(Scaled Dot Product Attention) olarak isimlendirilmektedir [66].


Dönüştürücü blok hücreleri içerisinde dikkat mekanizması bloklarının yanı sıra öz nitelik seviyesini yükseltmek amacıyla yapay sinir ağları, eğitim sürecini hızlandırmak amacıyla çeşitli katman normalizasyonu(Layer Normalization) teknikleri ve türev değerlerinin yok olması probleminin önüne geçmek için kullanılan çeşitli kısa yol bağlantıları(Shortcut Connections) da yer almaktadır [17], [67]. Şekil 3.35’de dönüştürücü mimarisini oluşturan birimler detaylı bir şekilde gösterilmektedir.



Şekil 3.35. Dönüştürücü mekanizması blok gösterimi [64]

Görüntü dönüştürücü mekanizmaları

Dönüştürücü mimarilerinin doğal dil işleme problemlerindeki başarısı, bu yaklaşımın görüntü problemlerine de uygulanabilme sorusunu akıllara getirmiştir. Bu kapsamda Dosovitskiy ve ekibi tarafından ilk kez görüntü üzerinden nesne tanıma problemlerine görüntü dönüştürücüler(Vision Transformers) mimarisi yaklaşımını geliştirmiştir. Şekil 3.36’da görüntü dönüştürücü mimari gösterilmektedir [68].



Şekil 3.36. Görüntü dönüştürücü mimarisi [68]

Dönüştürücü mimarileri, doğal dil işleme alanında giriş cümlesi içerisinde yer alan sıralı kelime vektörleri üzerinde çalışmaktadır. Bu kapsamda bu mimarinin görüntüye uygulayabilmek için ilk aşamada görüntüler, parça(Patch) adı verilen sıralı bölümlere ayrılmaktadır. İkinci aşamada, her bir parçanın görüntü üzerinde konum bilgisinden faydalanabilmek için, gömme(Embedding) adı verilen öğrenilebilir parametreler ile birleştirilmektedir. İlerleyen aşamalarda ise klasik dönüştürücü mimarinde olduğu gibi katman normalizasyonu, çoklu kafa dikkat mekanizmaları ve YSA içeren dönüştürücü bloğa maruz kalarak çıktı oluşturulmaktadır. Bu çıktılar problemin zorluğuna göre tekrardan dönüştürücü bloğuna verilerek daha yüksek seviyeli öz niteliklerin çıkartma işlemi gerçekleştirilmektedir. Son aşamada ise elde edilen çıktı, sınıflandırma katmanına verilerek görüntü tanıma problemi gerçekleştirilmektedir. Geliştirilen bu mimari ESA’na göre daha az işlem yüküne sahip olduğu gibi ve yüksek sayıda veri içeren veri setlerinde uygulandığında daha yüksek sonuçlar elde ettiği kanıtlanmıştır [68].

3.5.4. Evrişimsel sinir ağı modelleri


Evrişimsel Sinir Ağları kullanılarak yapılan bölütleme veya segmentasyon çalışmaları genel olarak örnek segmentasyonu ve semantik segmentasyon olmak üzere iki ayrı kategoride değerlendirilmektedir. Semantik bölütleme problemlerinde, görüntüde objelerin içerdiği her bir piksel objenin türüne göre önceden tanımlanmış bir sınıf etiketi atanırken, örnek bölütleme de ise aynı türe ait farklı objelere farklı sınıf etiketleri atanmaktadır. Gerçekleştirilen tez çalışması kapsamında SVH tespiti amacıyla damar bölümlerinin ayrıştırılması işlemi piksel seviyesinde sınıflandırma problemi olan semantik segmentasyon başlığı altında yer almaktadır.

Bu bölüm başlığı altında, medikal alanda semantik segmentasyon problemlerinde literatürde yaygın olarak kullanılan mimarilerin incelenmesi gerçekleştirilmiştir. İlerleyen bölümlerde ise bu mimariler gerçekleştirilecek olan beyin bölgesindeki damarların bölütlenmesi problemine uyarlanma işlemi sağlanmıştır. Böylece gerçekleştirilen tez çalışması kapsamında farklı mimarilerin başarıları kıyaslanarak, problem için en uygun mimarinin tespiti sağlanmıştır.

U-Net

U-Net mimarisi, Ronneberger ve arkadaşları tarafından 2015 yılında ışık mikroskobu vasıtasıyla elde edilen biyomedikal görüntüler üzerindeki çeşitli hücrelerin segmentasyonunu yapmak amacıyla geliştirilmiştir. Temelde Evrişimli Sinir Ağlarının bir araya getirilerek oluşturduğu bu mimari U-Net olarak adlandırılmaktadır. U-Net mimarisi literatürde yaygın olarak medikal görüntüler üzerinde kullanıldığı gibi, bilgisayarlı görü alanında gerçekleştirilen otonom sürüş için sahne algılama problemlerinde, uzaktan algılama ile elde edilmiş görüntülerin analizinde, sanal gerçeklik veya artırılmış gerçeklik gibi çeşitli problemlerde de aktif olarak kullanılmaktadır. Mimari yapısı ilerleyen sayfada Şekil 3.37’de görüleceği üzere U harfine benzer bir yapıdan meydana geldiğinden geliştirilen mimariye U-Net ismi verilmiştir [27]. Geliştirilen bu mimari, literatürde yer alan derin öğrenme tabanlı geliştirilen mimarilere kıyasla daha az veride daha yüksek skorlar elde edebilmektedir. Bu nedenle, literatürde U-Net mimarisinden medikal görüntüleme alanında yaygın olarak tercih edilmektedir.

Şekil 3.37’de görüleceği üzere U-Net mimarisi kodlayıcı(Encoder) ve kod çözücü(Decoder) adı verilen birbirine paralel iki bölümden meydana gelmektedir. İlk bölüm kodlayıcı adı verilen ve içerisinde yer alan her bir katmanda öz nitelik haritasının çözünürlük boyutu havuzlama katmanı vasıtasıyla azaltılmaktadır. Bu duruma ek olarak evrişimli sinir ağları içerisinde yer alan filtreleme işlemleri vasıtasıyla da çıkarılan öz niteliklerin seviyesi artmaktadır bu durum ölçek boyutundan bağımsız segmentasyon çıktısı sağlayarak başarılı bir şekilde öz niteliklerin oluşturulmasını sağlamaktadır.




Şekil 3.37. U-Net mimarisi [27]

U-Net mimarisinin ikinci bölümünde ise kodlayıcı kısmının son bölümünde elde edilen öz nitelik haritası tekrardan yukarı örnekleme(Up Sampling) işlemine maruz kalarak uzamsal çözünürlük boyutu artırılmaktadır. Çözünürlüğü artan öz nitelikler, tekrardan kodlayıcı bölümündeki öz niteliklerle birleştirilerek kodlayıcı bölümünde elde edilen öz niteliklerden faydalanılması sağlanmaktadır. Oluşturulan yeni öznitelikler tekrardan ESA maruz kalarak yüksek seviyeli yeni öz nitelik haritaları oluşmaktadır. Bu durum giriş görüntüsü boyutu elde edilinceye kadar tekrarlı bir şekilde devam etmektedir. Böylece segmentasyon işleminde ölçekten bağımsız, kenar ve köşe bölümlerinde daha başarılı bir segmentasyon çıktısı elde edilmektedir.

ResUNet

ResUNet mimarisi, 2017 yılında uzaktan algılanmış hava görüntüleri üzerinden yolların segmentasyonu problemini çözmek için geliştirilmiş mimaridir. Konsept olarak U-Net mimarisine oldukça benzer olduğu gibi birbiri arasındaki en temel fark ise mimari içerisinde yer alan kodlayıcı ve kod çözücü katmanlarında kısa yol adı verilen bağlantı yollarının(Shortcut Connections) yer almasıdır [69].


ResNet mimarisinde bilindiği üzere mimarilerin daha derin bir şekilde tasarlanabilmesi ve geri yayılım algoritması sonucunda üretilen türev değerlerinin yok olmasının önüne geçebilmek amacıyla kısa yol adı verilen bağlantılar geliştirmiştir [17]. Bu bağlantılar, U-Net içerisinde yer alan kodlayıcı ve kod çözücü kısımlarındaki her bir bölüme entegre edilerek, katmanlar içerisindeki bilgi akışını artırdığı gibi daha derin mimarilerinin oluşturulması ve verimli bir şekilde eğitilmesine imkan sağlamaktadır. Böylece kodlayıcı kısmından kod çözücü kısmına uzanan bağlantı yollarında da bilgi aktarımı daha kolay sağlanacağından daha az parametre ile daha fazla başarı skoru elde edilmektedir. Şekil 3.38’de ResUNet mimarisi detaylı bir şekilde gösterilmektedir.



Şekil 3.38. ResUNet mimarisi [72]

ResUNet++

ResUNet++ mimarisi, 2019 yılında kolorektal kanser hastalığının oluşmasına neden olan polip hücrelerinin endoskopi görüntüleri üzerinden segmentasyonu için geliştirilmiştir. ResUNet++ mimarisi, ResUNet mimarisinden esinlenilerek oluşturulduğundan kodlayıcı ve kod çözücü olmak üzere iki ana bölümden oluşmaktadır. UNet ve ResUNet mimarisinden farklı olarak kod çözücü kısmında kanalların birbiriyle olan ilişkilerinin çıkartmak için sıkıştırma ve uyarma blokları eklenmiştir[59]. Kenar, köşe gibi bölgelerde segmentasyon başarılarını artırmak ve kodlayıcı ile kod çözücü arasındaki geçiş kısmı olan köprü kısmına, filtrelerin etki ettikleri alanların görüş alanını artırmak amacıyla Atrous uzamsal piramit havuzlama katman bloğu kullanılmıştır[12]. Bu duruma ilave olarak kodlayıcı kısımdan gelen bilgiler ve kod çözücü kısımdaki bilgiler doğrudan birleştirmek yerine, kodlayıcı kısımdaki bilgileri kullanarak kod çözücü kısımdan gelen önemli öz niteliklerin belirginliğini artırmak için evrimsel dikkat mekanizma blokları kullanılmıştır [70]. Geliştirilen bu mimari, Şekil 3.39’da gösterilmektedir.




Şekil 3.39. ResUNet++ mimarisi [70]

TransUNet

TransUNet mimarisi, Chen ve arkadaşları tarafından 2021 yılında BTA cihazları vasıtasıyla elde edilmiş aort, böbrek, pankreas başta olmak üzere çeşitli organların segmentasyonu için geliştirilmiş derin öğrenme mimarisidir. Geliştirilen bu mimari görüntü sınıflandırma alanında en son teknoloji olan görüntü dönüştürücüleri, medikal görüntüleme alanında başarılı çıktılar veren UNet segmentasyon mimarisine entegre edilmesinden meydana gelmektedir [71].

Chen ve arkadaşları, motivasyon olarak ESA ile oluşturulan mimarilerde konvolüsyon operasyonunun doğasından gelen öğrenme yeteneği yerel olarak görüntü üzerindeki piksel bölgelerinde çalışmaktadır. Bu durum uzun menzilli bağımlılık içeren bölgelerin tespitinde hastadan hastaya farklılık gösteren şekil ve boyutlardan kolayca etkilendiğinden segmente edilen objelerin başarıları oranlarının düşük olmasına sebep olmaktadır. Bu kapsamda Chen ve arkadaşları görüntü dönüştürücüleri başlığı altında anlatılan dönüştürücü mimarilerini kullanarak küresel bir şekilde piksellerin birbirleriyle olan tüm ilişkilerini dikkate alarak segmentasyon başarısını artırmışlardır. Şekil 3.40'da geliştirilen mimarinin içeriği gösterilmektedir.



Şekil 3.40. TransUNet mimarisi [71]

Şekil 3.40’da gösterildiği üzere TransUNet mimarisi, kodlayıcı ve kod çözücü olmak üzere iki ana bölümden oluşmaktadır. Kod çözücü bölümü kendi içerisinde 4 farklı katmandan oluşmaktadır. İlk üç katman içerisinde evrimsel sinir ağlarını içeren konvolüsyon blokları vasıtasıyla görüntüyü oluşturan uzamsal çözünürlüklerin boyutları azaltılmaktadır. Son katmanda ise ardı ardına bağlı 12 adet görüntü dönüştürücü blok kullanarak öz niteliklerin birbirleriyle olan ilişkileri çıkartılmıştır. Böylece küresel bilgiyi içeren yeni öz nitelik haritası elde edilmiştir. Kod çözücü kısımda ise kodlayıcı kısmının son katmanındaki bilginin uzamsal çözünürlüğünü artırıp kendisine karşılık gelen kodlayıcı bölümündeki öz niteliklerle birleştirilmektedir. Bu işlem orijinal görüntü boyutuna ulaşmaya kadar devam etmektedir. Bu sayede kenar köşe gibi bölümlerde segmentasyon başarıları yüksek ve hastalar arası çok sayıda farklılık içeren tomografi görüntülerinde yüksek segmentasyon başarıları elde edilmektedir.

3.6. Performans Değerlendirme Metrikleri

Yapay zeka veya görüntü işleme alanında problemin türüne göre kullanılan değerlendirme metrikleri farklılık gösterebilmektedir. Örnek vermek gerekirse sınıflandırma uygulamalarında doğruluk metriği aktif olarak kullanılırken görüntü tabanlı segmentasyon problemlerinde doğruluk metriğini tek başına kullanmak modelin başarısını değerlendirme açısından yanlışlıklara sebep olabilmektedir. Bu kapsamda beyin bölgesinde yer alan damarlar bölümlerinin bölütlenmesi problemi segmentasyon problemi olduğundan ilerleyen bölümde segmentasyon problemlerinde kullanılan yaygın değerlendirme metriklerine değinilmiştir.

Değerlendirme metriklerinin hesaplanmasında ortak olarak, gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) bileşenleri kullanılmaktadır. TP, modelin doğru bir şekilde pozitif olarak sınıflandırdığı yani doğru şekilde tahmin yaptığı damar bölümlerinin örnek sayısını ifade ederken, TN ise modelin doğru bir şekilde negatif olarak sınıflandırdığı yani doğru şekilde tahmin yaptığı damar olmayan bölümlerin örnek sayısını ifade etmektedir. FP, modelin negatif olan örnekleri pozitif olarak sınıflandırdığı yani gerçekte damar olmayan bölümlere, damar dediği yanlış örnek sayısını ifade ederken, FN, modelin pozitif olan örnekleri negatif olarak sınıflandırdığı yani damar olan bölümlere, damar yok şekilde tahmin yaptığı yanlış örnek sayısını ifade etmektedir.

3.6.1. Piksel doğruluk metriği

Küresel doğruluk olarak da bilinen piksel doğruluğu (PD), görüntü içerisinde doğru şekilde sınıflandırılan piksellerin yüzdesini gösteren semantik segmentasyon metriğidir. PD, sınıftan bağımsız olarak görüntülerdeki doğru sınıflandırılmış piksel sayısı ile görüntü içerisindeki toplam piksel sayısı arasındaki oranı hesaplamaktadır. PD, sezgisel ve yorumlanabilir bir ölçüm metriğidir. Bu sebeple bu değerin yüksek olması segmentasyon başarısını tam anlamıyla doğru olduğunu ifade etmemektedir. Bunun temel nedeni, damar segmentasyon probleminde arka plan ve ön plan olmak üzere iki farklı sınıf bulunmaktadır. Görüntü içerisindeki damarlar ön plan olarak adlandırılırken, diğer bölümler ise arka plan olarak adlandırılmaktadır. Manyetik Rezonans Anjiyografi görüntülerinde yaklaşık olarak tüm piksellerin %0.004 lük kısmı damar içerdiğinden – geliştirilen model tüm görüntüye arka plan olarak çıktı verse bile başarı değeri %99.996 olmaktadır. Bu durum geliştirilen modelin yanlış yorumlanmasına neden olabilmektedir. Bu kapsamda, piksel doğruluğu metriğine ait ilişkin matematiksel ifade aşağıda gösterilmektedir.

$$\text{Piksel Doğruluğu} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.17)$$

3.6.2. Kesinlik metriği

Kesinlik(Precision) metriği segmentasyon problemi içerisinde yer alan her bir sınıf için ayrı ayrı tanımlandığı gibi sınıfların ortalaması şeklinde de gösterilebilir. Gerçekleştirilen tez çalışması kapsamında kesinlik değeri ön plan sınıfı olarak adlandırılan damar bölümleri için hesaplanmıştır. Kesinlik metriği temelde geliştirilen model tarafından damar olarak tahmin edilen piksel bölümlerinin ne kadarının gerçekten damar olduğu oranını bizlere ifade etmektedir. Bu değerlendirme metriği ne ilişkin formül aşağıda gösterilmiştir;

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.18)$$

3.6.3. Duyarlılık metriği

Duyarlılık(Recall) metriği segmentasyon problemi içerisinde yer alan her bir sınıf için ayrı ayrı tanımlandığı gibi sınıfların ortalaması şeklinde de gösterilebilir. Gerçekleştirilen tez çalışması kapsamında duyarlılık değeri ön plan sınıfı olarak adlandırılan damar bölümleri için hesaplanmıştır. Duyarlılık metriği temelde geliştirilen modelin görüntü içerisinde yer alana damar piksel bölümlerinin ne kadarının doğru bulunduğu oranını bizlere ifade etmektedir. Bu değerlendirme metriği ne ilişkin formül aşağıda gösterilmiştir;

$$Duyarlılık = \frac{TP}{TP+FN} \quad (3.19)$$

3.6.4. F Değeri (F Score)

F değeri, kesinlik ve duyarlılık metriğinin birleştirilmesiyle oluşturulmuştur. Bu metrik Dice kat sayısı olarak da adlandırılır ve temelde kesinlik ve duyarlılık metriklerinin harmonik ortalaması alınarak hesaplanmaktadır. Bu değerlendirme metriği ne ilişkin formül aşağıda gösterilmiştir;

$$F_{Değeri} = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.20)$$

3.6.5. Jaccard indeksi(Intersection Over Union)

Jaccard indeksi olarak da adlandırılan (IoU) metriği, semantik bölümlerde en yaygın kullanılan metriklerden biridir. IoU, temelde etiketlenmiş gerçek maske görüntüsü ile model tarafından tahmin edilen maske çıktısı arasındaki örtüşmenin yüzdesini ölçmek için kullanılan bir yöntemdir. Bu metrik, 0 ile 1 arasında değişir; 0, örtüşme olmadığını simgelerken 1 değeri ise mükemmel şekilde örtüşen segmentasyon sonuçlarını ifade etmektedir. IoU metriği, her bir sınıf için ayrı ayrı tanımlandığı gibi sınıfların ortalaması şeklinde(mIoU) de gösterilebilir. Gerçekleştirilen tez çalışması kapsamında ön plan ve arka plan olarak adlandırılan iki sınıf için mIoU değeri hesaplanmıştır. Bu değerlendirme metriği ne ilişkin formül aşağıda gösterilmiştir;

$$mIoU = \frac{1}{C} \frac{TP}{TP+FP+FN} \quad (3.21)$$



4. GERÇEKLEŞTİRİLEN UYGULAMALAR VE SONUÇLARIN İNCELENMESİ

Tez çalışması kapsamında, SVH tespitinde faydalanılacak olan damar bölümlerinin segmentasyon problemi için görüntü işleme ve derin öğrenme tabanlı olmak üzere iki farklı yöntem geliştirilmiştir. Bu bölüm altında ilk olarak çalışma içerisinde kullanılacak olan veri setine değinilmiş olup ilerleyen aşamalarda sırasıyla görüntü işleme ve derin öğrenme tabanlı teknikler detaylı bir şekilde açıklanmaktadır.

4.1. Çalışma Kapsamında Kullanılan Veri Seti

Gerçekleştirilen tez çalışması, Lozan Üniversite Hastanesi tarafından anevrizma hastalığının bilgisayar destekli teknikler vasıtasıyla tespit işlemi için hazırlanan veri seti üzerinde gerçekleştirilmiştir. İncelenen veri seti, toplamda 284 hasta görüntüsü içermektedir. Bu görüntülerin 127 tanesi sağlıklı hastaya aitken, 157 tanesinde anevrizma hastalığı tespit edilen hastalara aittir. Veri seti içerisinde yer alan tüm hasta görüntüleri MRG cihazları vasıtasıyla üç boyutlu uçuş süresi zaman protokolünde çekilmiş kesit görüntülerinden meydana gelmektedir. Araştırmacıların çalışabilmesi ve medikal alanda yapılan çalışmaların artırılması amacıyla veri seti herkesin erişimine açıktır. Bu kapsamda konu ile alakalı çalışma yapmak isteyenler openneuro.org adresinden veri setine erişim sağlayabilirler [72].



Resim 4.1. Veri seti erişim bilgileri [73]

SVH tespiti için gerekli olan damar bölümlerinin segmentasyonu için geliştirilecek olan tekniklerin ilk aşamasında, tüm hasta verileri taranarak yüksek kalitede görüntü serilerine sahip olan hastalar özenle belirlenmiştir. Bunun temel nedeni olarak, geçmişli yıllara ait görüntüler içerisinde ağırlıklı olarak hastalar çekim işlemi sırasında hareket etmesinden kaynaklı bulanık ve keskin olmayan görüntü dizileri yer almaktadır. Bu durum beraberinde, bazı görüntülerde çeşitli artefaktlar oluşmasına da neden olmuştur.

Gerçekleştirilen çalışma kapsamında veri seti içerisinde hasta seçimleri yapılırken, çözünürlük sınırı olarak 512 x 512 belirlenmiş olup, bu değere eşit veya yüksek çözünürlükteki görüntü serilerine sahip 40 adet hasta seçilmiştir. Seçilen hasta görüntülerinde, çekim sırasında hasta hareketinden kaynaklı görüntü üzerinde oluşabilecek herhangi bir problem amacıyla manuel bir şekilde kontrol edilmiştir. Bu kapsamda elde edilmiş veriler, ağırlıklı olarak Philips ve Siemens marka cihazlarda uçuş süresi zaman protokolünde verilerin elde edildiği gözlemlenmiştir. Böylece seçilen 40 hastaya ait makine, model ve görüntü bilgileri Çizelge 4.1’de detaylı bir şekilde gösterilmektedir;

Çizelge 4. 1. Veri setini oluşturan veri dağılımı


Marka	Model	Piksel Aralığı	Çözünürlük	Adet
Philips	Intera	0.41 mm x 0.41 mm x 0.55 mm	512 x 512 x 140	1
Siemens	Skyra	0.27 mm x 0.27 mm x 0.50 mm	652 x 768 x 168	13
Siemens	Skyra	0.23 mm x 0.23 mm x 0.70 mm	720 x 896 x 160	9
Siemens	Verio	0.23 mm x 0.23 mm x 0.70 mm	700 x 896 x 160	4
Siemens	Prisma Fit	0.28 mm x 0.28 mm x 0.50 mm	696 x 768 x 200	12
Siemens	Aera	0.35 mm x 0.35 mm x 0.50 mm	512 x 512 x 152	1

Gerçekleştirilen çalışmanın ilk bölümünde, damar bölümlerinin otomatize bir şekilde etiketlenmesi amacıyla görüntü işleme tabanlı teknik geliştirilmiştir. Bu teknik vasıtasıyla hızlı bir şekilde görüntülerin etiketlenme işlemi yapılabilmektedir. İkinci aşamada ise üretilen veri seti vasıtasıyla, damar bölümlerinin segmentasyonu için kullanılacak olan evrişimsel sinir ağı tabanlı mimariler kullanılarak eğitim işlemi gerçekleştirilmiştir. Bu kapsamda görüntülerin etiketlenmesi ile alakalı detaylar ilgili bölüm altında detaylı olarak verilmektedir.

4.2. Görüntü İşleme Teknikleriyle Damar Bölümlerinin Segmentasyonu

Bu bölümde, SVH tespiti kapsamında damar segmentasyon problemi için geliştirilen görüntü işleme tabanlı tekniklerden bahsedilmiştir. Geliştirilen tekniğin ilk aşamasında, Sato ve arkadaşları tarafından Hesse matris tabanlı filtreleme kullanılarak damar bölümleri tespit edilmektedir. İkinci aşamada ise bağlı bileşen etiketleme tekniği vasıtasıyla FP şeklindeki damar olmayan bölgelerin ortadan kaldırılması sağlanmaktadır. Son aşamada ise damar bölümleri üzerinde bölge büyütme algoritması kullanılarak damarların segmentasyon başarıları artırılmaktadır.

Bu kapsamda, bölüm içerisinde gerçekleştirilecek olan algoritmalara ait akış diyagramı Şekil 4.1’de gösterilmektedir;



Şekil 4.1. Görüntü işleme tabanlı sistem akış diyagramı

4.2.1. Sato filtreleme

Sato ve arkadaşları tarafından 1997 yılında geliştirilen damar bölütleme yaklaşımı, bu alandaki ilk çalışmalardan birisi olarak kabul edilmektedir [7]. Temelinde ikinci derece türevsel analize dayanan bu yaklaşım dört aşamadan oluşmaktadır. İlk aşamada, Gaussian filtresinin ikinci derece kısmi türev bileşenlerine ayrılmaktadır. İkinci aşamada elde edilen kısmi türevler, görüntü üzerine konvolüsyon işlemine tabi tutularak Hesse matrisi hesaplanmaktadır. Bu kapsamda MRA görüntülerinde kullanılacak olan üç boyutlu Gaussian filtresi Eşitlik 4.1'de gösterilmektedir. Eşitlik içerisindeki sigma(σ) parametresi vasıtasıyla, beyin bölgesi içerisinde yer alan küçük veya büyük damarların ayrıştırma işlemi sağlanmaktadır.

$$G(x, y, z; \sigma) = \frac{1}{(2\pi\sigma^2)^{3/2}} e^{-\frac{x^2+y^2+z^2}{2\sigma^2}} \quad (4.1)$$

Hesse matrislerinin elde edilebilmesi amacıyla her bir piksel için ikinci dereceden kısmi türevlerin tüm yönlü olacak şekilde hesaplanması gerekmektedir. Bu kapsamda, Eşitlik 4.1'de gösterilen üç boyutlu Gaussian filtresinin ikinci dereceden kısmi türev bileşenleri, tüm yönlü olacak şekilde hesaplanmaktadır. Bu nedenle Sato ve arkadaşları tarafından geliştirilen yaklaşımın ilk aşamasında, Gaussian filtrenin kısmi türev bileşenleri elde edilerek, görüntü ile konvolüsyon işlemine maruz kalmaktadır. Bu bağlamda, aşağıda yer alan matematiksel ifadelerde Hesse matrisi elde etme aşamasında kullanılacak olan kısmi türevler gösterilmektedir.

$$I_{xx} = \left(\sigma^2 x \frac{\partial^2}{\partial x^2} G(x, y, z; \sigma) \right) * I(x, y, z) \quad (4.2)$$

$$I_{xy} = \left(\sigma^2 x \frac{\partial^2}{\partial x \partial y} G(x, y, z; \sigma) \right) * I(x, y, z) \quad (4.3)$$

$$I_{xz} = \left(\sigma^2 x \frac{\partial^2}{\partial x \partial z} G(x, y, z; \sigma) \right) * I(x, y, z) \quad (4.4)$$

$$I_{yy} = \left(\sigma^2 x \frac{\partial^2}{\partial y^2} G(x, y, z; \sigma) \right) * I(x, y, z) \quad (4.5)$$

$$I_{yz} = \left(\sigma^2 x \frac{\partial^2}{\partial y \partial z} G(x, y, z; \sigma) \right) * I(x, y, z) \quad (4.6)$$

$$I_{zz} = \left(\sigma^2 x \frac{\partial^2}{\partial z^2} G(x, y, z; \sigma) \right) * I(x, y, z) \quad (4.7)$$

Sato filtrelemenin ikinci aşamasında, ilk aşamada hesaplanan kısmi türevler kullanılarak, görüntüdeki her piksel için parlaklık değişimleri bulunmaktadır. Bu değişimler, Hesse matris denkleminde yerleştirildiğinde, her bir piksel için Şekil 4.1 üzerinde görüleceği üzere 3 x 3 kare matris oluşmaktadır.

$$H = \begin{pmatrix} I_{xx} & I_{xy} & I_{xz} \\ I_{yx} & I_{yy} & I_{yz} \\ I_{zx} & I_{zy} & I_{zz} \end{pmatrix}$$

Şekil 4.2. Üç boyutlu Hesse görüntü matrisi

Yukardaki şekilde gösterilen Hesse matrisi, "H" ile simgelenmektedir ve öz değer ve öz vektörlerinin bulunabilmesi için sırasıyla aşağıda gösterilen lineer cebir eşitliklerinden faydalanılmaktadır. Eşitlik içerisinde yer alan "λ" sembolü öz değerleri simgelerken "ē" sembolü ise öz vektörleri simgelemektedir. Kısaca bu değerler vasıtasıyla yüzey üzerindeki maksimum ve minimum eğrilik yön ve büyüklükleri hesaplanmaktadır. İlerleyen aşamada, öz vektörlerin sıfır olmadığı bilindiğinden, eşitliğin sol tarafındaki kalan kısmın singular çözüme sahip olması gerekmektedir. Bu sebeple, eşitliğin sol bölümündeki determinant sıfır kabul edilerek, 3. dereceden denklemlerin çözümü vasıtasıyla öz değerler bulunmaktadır. Bu öz değerlerin de tekrardan formül içerisine yerleştirilmesi ile öz vektörler hesaplanmaktadır.

$$A\vec{e} = \lambda\vec{e} \quad (4.8)$$

$$A\vec{e} = \lambda I\vec{e} \quad (4.9)$$

$$(A - \lambda I)\vec{e} = 0 \quad (4.10)$$

$$\det(A - \lambda I)\vec{e} = 0 \quad (4.11)$$

Sato ve ekibinin çalışmasına göre damar şeklinde yapılar genelde boru biçimindeki yapılarla benzerlik göstermektedir. Bu nedenle geliştirilecek filtre, boru şeklindeki yapılarda yüksek seviye filtre yanıt üretmesi gerekmektedir. Sato ve arkadaşları, bu nedenle öz değerlerin birbirine göre oranlanması yoluyla bu tür yapıların tespit edilebileceğini ileri sürmüştür. Bu sebeple boru biçimindeki yapılar için öz değerler küçükten büyüğe doğru sıralandığında, en küçük öz değerler yaklaşık olarak 0 değerini üretirken diğer öz değerler görüntünün parlaklık ya da koyuluk durumuna göre en küçük öz değerden çok büyük veya çok küçük değer olma durumundadır. Bu sebeple küçük olan öz değerlerin büyük olan öz değerlere göre oranlanması kullanılarak damar olma skor değerlerinin hesaplanmasını sağlamaktadır. Bu kapsamda Sato ve arkadaşları tarafından geliştirilen damar olma skor fonksiyonunun matematiksel ifadesi aşağıda gösterilmiştir;

$$\lambda_c = \min(-\lambda_2, -\lambda_3) \quad |\lambda_1| \ll |\lambda_2|, \quad |\lambda_1| \ll |\lambda_3| \quad (4.12)$$

$$f(\lambda_1; \lambda_c) = \begin{cases} e^{\left(-\frac{\lambda_1^2}{2(\sigma_1\lambda_c)^2}\right)} & \lambda_1 \leq 0, \lambda_c \neq 0 \\ e^{\left(-\frac{\lambda_1^2}{2(\sigma_2\lambda_c)^2}\right)} & \lambda_1 > 0, \lambda_c \neq 0 \end{cases} \quad (4.13)$$

Eşitlik 4.12'de belirtildiği gibi, boru şeklindeki yapılar için öz değerler küçükten büyüğe doğru sıralandığında, bir adet küçük öz değer bulunurken diğer öz değerler, küçük öz değere göre oldukça büyük ya da küçük olmaktadır. Çeşitli durumlarda öz değerler negatif veya pozitif gelebilmektedir bu durumun temel nedeni, görüntü içerisindeki objelerin parlaklık değişiminden kaynaklanmaktadır. Genellikle karanlık bir arka plandaki beyaz objelerin oluşturacağı öz değerler negatif işarete sahip olurken, beyaz bir arka plandaki karanlık objelerin oluşturacağı öz değerler ise pozitif değer almaktadır. Bu sebeple uçuş süresi zaman protokolünde çekilen MRA görüntüleri referans alındığında, öz değerlerin negatif geldiği gözlemlenmektedir. Bu sebeple ikinci ve üçüncü öz değerlerin negatif işareti alınırken damar olma skor fonksiyonunda daha iyi sonuç üretmesi açısından küçük olan kullanılmaktadır.

Eşitlik 4.13’de görüleceği üzere, damar bölümlerinin skorunun hesaplanmasında kullanılacak olan fonksiyon incelendiğinde, damar yapılarında genellikle küçük olan öz değer sıfıra yakın ve büyük olan öz değer ise sıfırdan çok büyük olmaktadır. Bu nedenle iki öz değerinin birbirine göre oranlanması sıfıra yakın bir sonuç getirmektedir. Üretilen bu sonuç değerinin, üsteli alındığında ise damar olma skoru açısından 1 değeri elde edilmektedir. Bu sayede, damar gibi yapılar için fonksiyon sonucu yaklaşık olarak 1 olurken, damar olmayan yapılar için sonuç 1’den uzak olmaktadır. Formül içerisinde α_1 ve α_2 sırasıyla görüntü üzerindeki gürültülerin bastırılması ve yumuşak bir sonuç üretilmesini sağlamaktadır. Genellikle bu değerler sırasıyla 0.5 ve 2 olarak belirlenmektedir.

Sato ve ekibi, geliştirdikleri filtrenin arter gibi sadece büyük damarlarda değil, aynı zamanda farklı ölçeklerdeki damar bölümlerinde de başarılı bir şekilde çalışması gerektiğini hedeflemişlerdir. Bu amaçla Gaussian filtreleme içerisindeki sigma parametresini kullanarak, farklı ölçek değerlerinde Hesse matrisleri elde etmişlerdir. Bu matrisler, damar olma skor fonksiyonuna girdi sağlanarak, her bir ölçekteki her bir piksel değeri için damar skoru üreten çıktı değeri hesaplanmaktadır. Oluşturulan farklı ölçeklerdeki çıktılar, her bir piksel konumunun farklı ölçekleri arasında maksimum filtre yanıtı alınarak farklı boyutlardaki damarların segmentasyonu gerçekleştirilmektedir.


$$L = f(\lambda_1; \lambda_c) \times \lambda_c \quad (4.14)$$

$$\max \left(\frac{1}{n_i} L_i(x, y, z) \right) \quad (4.15)$$


Son aşamada, görüntü içerisinde gürültünün fazla olduğu durumlarda türev değerleri yüksek yanıt vermektedir ve buna bağlı olarak da damar olmayan bölümlerde yüksek değerli Hesse matrisleri üretilmektedir. Bu durum, ikinci aşamada gerçekleştirilen maksimum alma işlemi sırasında hataların oluşmasına sebep olmaktadır. Bu problemin önüne geçmek için Sato ve arkadaşları farklı ölçek değerlerindeki görüntülerden 16x16x16 patchler alarak gürültü değerinin standart sapmasını tahmin etmişlerdir. Bu değer Eşitlik 4.16 içerisinde “ n_i ” harfiyle gösterilmektedir. Böylece geliştirilen yaklaşım farklı ölçeklerdeki damarın bölütleme işleminde de başarılı ile sonuçlar üretmektedir.

Sato filtreleme tekniğinin sonuçları


Bu bölüm içerisinde Sato ve arkadaşları tarafından damar bölümlerinin bölütlenmesi için geliştirilen filtrenin farklı hastalara ait MRA görüntülerinde ürettiği sonuçlar gösterilmektedir. Bu kapsamda incelenen ilk hastanın verisi, 3 Tesla manyetik alan gücüne sahip Philips marka Intera model MRA cihazı tarafından 3 boyutlu uçuş süresi zaman çekim protokolünde elde edilmiş görüntü serisi üzerinde gerçekleştirilmiştir. Filtre içerisindeki farklı boyutlardaki damarların tespitinde etkili olan Gaussian filtrenin sigma parametresi bu hasta için 2 olarak kaydedilmiştir. Eşitlik 4.14’de yer alan α_1 ve α_2 parametreleri sırasıyla 0.5 ve 2 seçilmiştir. Bu kapsamda filtreleme sonucu oluşan bölütleme çıktıları aşağıdaki şekillerde gösterilmektedir;



Resim 4.2. İlk hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları




Resim 4.3. İlk hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları




Resim 4.4. İlk hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları

Yukarıdaki şekillerde görüleceği üzere, orijinal MRA görüntüleri sol tarafta verilmişken sağ tarafta ise filtreleme sonucunda oluşan segmentasyon görüntüleri yer almaktadır. İnceleme sırasında, iki boyutlu görüntü serilerinin detaylı incelenmesinin yanı sıra hacim oluşturma teknikleri kullanılarak da hastaların damar bölümlerinin incelenmesi sağlanmaktadır. Genellikle bu işlem çeşitli hacim oluşturma teknikleri vasıtasıyla gerçekleştirilmektedir. Bu kapsamda ilk hastaya ait 3 boyutlu hacim görüntüsü aşağıdaki şekilde gösterilmektedir;




Resim 4.5. İlk hastaya ait 3 boyutlu segmentasyon çıktısı


Çalışma kapsamında incelenen ikinci hastanın verisi 3 Tesla manyetik alan gücüne sahip Siemens marka Skyra model MRA cihazı tarafından 3 boyutlu uçuş süresi zaman çekim protokolünde elde edilmiş görüntü serisi üzerinde gerçekleştirilmiştir. Filtre içerisindeki farklı boyutlardaki damarların tespitinde etkili olan Gaussian filtrenin sigma parametresi bu hasta için de 2 olarak kaydedilmiştir. Eşitlik 4.14 üzerinde yer alan α_1 ve α_2 parametreleri de sırasıyla 0.5 ve 2 seçilmiştir. Bu kapsamda filtreleme sonucu oluşan iki boyutlu bölütleme çıktıları aşağıdaki şekillerde gösterilmektedir;



Resim 4.6. İkinci hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları




Resim 4.7. İkinci hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları



Resim 4.8. İkinci hastanın kesit görüntüsündeki orijinal ve segmentasyon çıktıları

Yukarıdaki şekillerde görüleceği üzere, ikinci hasta için orijinal MRA görüntüleri sol tarafta verilmişken sağ tarafta ise filtreleme sonucunda oluşan segmentasyon görüntüleri yer almaktadır. İnceleme sırasında, iki boyutlu görüntü serilerinin detaylı incelenmesinin yanı sıra hacim oluşturma teknikleri kullanılarak da hastaların damar bölümlerinin incelenmesi sağlanmaktadır. Bu kapsamda ilk hastaya ait 3 boyutlu hacim görüntüsü aşağıda gösterilmektedir;




Resim 4.9. İkinci hastaya ait 3 boyutlu segmentasyon çıktısı

4.2.2. Bağlı bileşenlerin etiketlenmesi

Bağlı birleşen etiketleme(Connected Component Labelling) tekniği, görüntü işleme alanında, ayırık nesne bölgelerini belirlemek ve her bir nesneye farklı bir etiket veya numara vermek için geliştirilen bir yöntemdir. Bağlı birleşen etiketleme(CCL) tekniği, genellikle bağlı birleşenlerin analizi(Connected Component Analysis) ile birlikte kullanılarak bir görüntü içerisindeki ayırık nesne bölgelerinin sayısını, yapısını ve konumlarını belirleme de kullanılmaktadır.

Bağlı birleşen etiketleme tekniği temelde, görüntüdeki her bir pikselin birbirleriyle nasıl bağlantılı olduğunu belirleyerek çalışmaktadır. Bu kapsamda, eğer iki piksel aynı nesneye aitse, aynı etikete sahip olurken, farklı nesnelere ait ise farklı etiketlere sahip olmaktadır. Bu işlem de genellikle dört yönlü veya sekiz yönlü komşuluk bağlantıları adı verilen iki farklı bağlantı yöntemi kullanılarak gerçekleştirilmektedir. Bu kapsamda, Şekil 4.2’de 4’lü ve 8’li komşuluk bağlantıları gösterilmektedir.




Şekil 4.3. Farklı bağlantı komşuluklarının gösterimi [74]

Bağlı birleşen etiketleme tekniğinin çalışması için öncelikle maske adı verilen ikili formatta görüntünün elde edilmesi gerekmektedir. Bu sebeple genellikle görüntü işleme uygulamalarında eşikleme vasıtasıyla ilk adım olarak ikili görüntü elde edilmektedir. İkinci aşamada, maske görüntüsündeki her bir piksel için sırasıyla Şekil 4.2 üzerinde yer alan komşuluklarına bakılmaktadır. Eğer komşulukları üzerinde önceden etiketlenmiş bir piksel var ise ilgili pikselde bu etikete sahip olurken, herhangi bir etiketlenmiş piksel yok ise bu piksele yeni bir etiket atanmaktadır. Bu duruma ek olarak, komşu piksellerde iki farklı etiketlenme durumu söz konusu ise bu iki etiketin de benzer objeye ait olduğu referans alınarak sonuç etiket görüntüsü oluştururken etiket değerleri aynı olacak şekilde


değiştirilmektedir. Bu işlem görüntü içerisindeki tüm pikseller boyunca benzer şekilde tekrar etmektedir.

Bağılı bileşenlerin etiketlenmesi tekniğinin uygulanması

Tez çalışması kapsamında, bağlı birleşen etiketleme tekniği Sato filtreleme sonucunda oluşmuş bölütleme maskesi içerisindeki yanlış etiketlenmiş damar olmayan bölümler ile kılcal damar gibi küçük damar bölümlerinin kaldırılması amacıyla kullanılmaktadır. Bu kapsamda üç boyutlu maske görüntüsü üzerinden 300 voksel altında damar içeren bölümler belirlenerek görüntü üzerinden kaldırılmıştır. Bu kapsamda ilk hastaya ait bazı kesit görüntülerinde algoritma çıktısı aşağıdaki gibidir;




Resim 4.10. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları




Resim 4.11. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları

Bir önceki sayfadaki şekillerde görüleceği üzere, ilk hasta için Sato filtreleme sonrası oluşan segmentasyon çıktı görüntüleri sol tarafta gösterilirken, sağ tarafta ise bağlı bileşenlerin etiketlenmesinin ardından 300 vokselden küçük bölümlerin kaldırılmasıyla oluşan segmentasyon çıktı görüntüleri yer almaktadır. Resim 4.12’de ise ilk hastaya bağlı birleşen analiz tekniğinin uygulanması ardından 3 boyutlu hacim görüntüsü gösterilmektedir;




Resim 4.12. İlk hastaya ait bağlı bileşen etiketleme tekniğinin üç boyutlu çıktısı

İkinci hasta için de üç boyutlu maske görüntüsü üzerinden 300 voksel altında damar içeren bölümler belirlenerek görüntü üzerinden kaldırılmıştır. Bu kapsamda ikinci hastaya ait çıktı segmentasyon görüntüleri aşağıdaki şekillerde gösterilmektedir;




Resim 4.13. Sato filtreleme ve bağlı bileşen etiketleme tekniklerinin çıktıları



Resim 4.14. Sato filtreleme ve bağılı bileşen etiketleme tekniklerinin çıktıları


Yukarıdaki şekillerde görüleceği üzere, ikinci hastanın Sato filtreleme sonrası oluşan segmentasyon çıktı görüntüleri sol tarafta gösterilirken, sağ tarafta ise bağılı bileşenlerin etiketlenmesinin ardından 300 vokselden küçük bölümlerin kaldırılmasıyla oluşan segmentasyon çıktı görüntüleri yer almaktadır. Resim 4.15’de ise ikinci hastaya ait 3 boyutlu hacim görüntüsü gösterilmektedir;




Resim 4.15. İkinci hastaya ait bağılı bileşen etiketleme tekniğinin üç boyutlu çıktısı

Bölge büyütme tekniğinin uygulanması

Bölge büyütme tekniği, Sato filtreleme ve ardından bağlı bileşenlerin etiketlenmesi tekniğinin uygulanarak, 300 vokselden küçük damar bölümlerinin silinmesiyle oluşturulan maske görüntüleri üzerine uygulanmıştır. Bölge büyütme algoritmasında kullanılacak eşik kriter değeri ise küçükten büyüğe sıralanmış piksellerin 99,7 yüzdelik değerine karşılık gelen parlaklık değeri seçilmiştir. Bu kapsamda ilk hastaya ait sonuç görüntüleri aşağıdaki şekillerde gösterilmektedir;




Resim 4.16. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları




Resim 4.17. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları

Yukarıdaki şekillerde görüleceği üzere, ilk hastanın bağlı bileşenlerin etiketlenmesi tekniğinin çıktıları sol tarafta yer alırken, sağ tarafta bölge büyütme algoritma çıktıları yer almaktadır. Bölge büyütme algoritması ile damar olan fakat damar olarak etiketlenmemiş bölümlerinde etiketlenerek segmentasyon başarısı artırılmıştır. Bu kapsamda Şekil 4.18’de ilk hastaya ait bölge büyütme algoritmasının üç boyutlu görüntüsü gösterilmektedir;




Resim 4.18. İlk hastaya ait bölge büyütme tekniğinin üç boyutlu çıktısı

İkinci hasta içinde bölge büyütme algoritmasında kullanılacak eşik kriter değeri de piksellerin küçükten büyüğe sıralanarak 99,7 yüzdelik değerine karşılık gelen parlaklık değeri seçilmiştir. Bu kapsamda ikinci hastaya ait sonuç görüntüleri aşağıdaki şekillerde gösterilmektedir;




Resim 4.19. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları



Resim 4.20. Bağlı bileşen etiketleme ve bölge büyütme tekniklerinin çıktıları

Yukarıdaki şekillerde görüleceği üzere, ikinci hastanın bağlı bileşenlerin etiketlenmesi tekniğinin çıktıları sol tarafta yer alırken, sağ tarafta bölge büyütme algoritma çıktıları yer almaktadır. Bölge büyütme algoritması ile damar olan fakat damar olarak etiketlenmemiş bölümlerinde etiketlenerek segmentasyon başarıları artırılmıştır. Bu kapsamda Resim 4.21’de ikinci hastaya ait hacim oluşturma tekniği çıktılarının 3 boyutlu görüntüsü gösterilmektedir;



Resim 4.21. İkinci hastaya ait bölge büyütme tekniğinin üç boyutlu çıktısı


4.2.4. Görüntü işleme sonuçlarının değerlendirilmesi

Gerçekleştirilen tez çalışması kapsamında detaylı bir şekilde etiketlenen 3 farklı hasta üzerinde görüntü işleme tabanlı geliştirilen algoritmanın oluşturduğu segmentasyon başarıları aşağıda gösterilmektedir.

Çizelge 4.2. Test görüntüleri üzerinde algoritma çıktılarının değerlendirilmesi

	Marka	Model	Piksel Doğruluğu	Ortalama Jaccard İndeksi	Kesinlik	Duyarlılık	F Skor
Hasta 1	Siemens	Skyra	0.9973	0.7042	0.9403	0.4255	0.5859
Hasta 2	Siemens	Skyra	0.9961	0.6862	0.7755	0.4259	0.5499
Hasta 3	Philips	Intera	0.9972	0.7248	0.7381	0.5787	0.6484

Tez çalışması kapsamında, görüntü işleme tabanlı damarların segmentasyonu için geliştirilmiş teknik ne kadar başarılı olsa da parametrik oluşu sebebiyle farklı MRA cihazlarında veya farklı hastalarda yukarıdaki çizelgede görüldüğü gibi bölütleme başarısının düşük olmasına sebep olabilmektedir. Bu kapsamda Resim 4.24'te farklı bir hastaya ait farklı MR cihazı tarafından elde edilmiş görüntüde, kafatası bölgesinde algoritmanın damar olarak etiketlediği yanlış çıktı görüntü örneği gösterilmektedir;



Resim 4.22. Farklı bir hastanın algoritma çıktı kesit görüntüsü

Gerçekleştirilen tez çalışmasının ilerleyen bölümlerinde ise son yıllarda popüler olan derin öğrenme tabanlı yaklaşımların beyin bölgesi içerisinde yer alan damarların bölütleme probleminde uygulanması sağlanmaktadır. Geliştirilen görüntü işleme tabanlı teknikten ise derin öğrenme tabanlı algoritmalar tarafından ihtiyaç duyulan etiketli veri seti oluşturma işleminde aktif olarak faydalanılmaktadır.

4.3. Derin Öğrenme Teknikleriyle Damar Bölümlerinin Segmentasyonu

Bu bölümde, SVH tespiti kapsamında damar segmentasyon problemleri için geliştirilen derin öğrenme tabanlı teknikler hakkında bilgi verilmiştir. Tez kapsamında gerçekleştirilen çalışmalarda, beyin bölgesinde yer alan damar bölümlerinin segmentasyonu problemi için iki farklı yaklaşım denenmiştir. İlk çalışma, beyindeki ana serebral arterlerin segmentasyonu için gerçekleştirilirken, ikinci yaklaşımda ise artefaktlar sebebiyle kafatası bölümünden 10 mm geride kalan kısımlarda yer alan tüm arterlerin bölütlenmesi gerçekleştirilmektedir.

4.3.1. Etiketli veri setinin oluşturulması

Beyin bölgesindeki damarların bölütlenmesi probleminde derin öğrenme tabanlı yaklaşımlarımdan faydalanabilmek amacıyla, öncelikle etiketli bir şekilde veri setinin oluşturulması gerekmektedir. Bu kapsamda bu bölüm içerisinde iki farklı yaklaşım için etiketli bir şekilde veri seti oluşturma işleminden detaylı bir şekilde bahsedilmiştir.

Ana serebral arterler için etiketli veri seti oluşturulması


Derin öğrenme tabanlı tez çalışmasının ilk bölümünde ana serebral arterlerin segmentasyonu üzerine odaklanılmıştır. Ana serebral arterler, beyne ve çevresindeki yapılara temel kan akışını sağlayan ve beynin tabanında bulunan halka benzeri bir arteriyel yapıdır. Genellikle, anevrizma gibi çeşitli serebrovasküler hastalıkların birçoğu bu bölge üzerinde yer alan damarlarda meydana gelmektedir. Bu nedenle bu bölgenin doğru bir şekilde bölütleme işlemi, hastalık teşhisi için oldukça önem taşımaktadır. Resim 4.23'te ana serebral arterleri içeren MRA görüntüsü üzerinde gösterilmektedir;




Resim 4.23. Ana serebral arter bölgesinin MRA görüntülerinde gösterimi [75]

Uçuş zaman süresi çekim protokolündeki MRA görüntüleri çok sayıda kesit görüntüsünden oluşmaktadır. Hastaya ait MRA kesit görüntüler detaylı incelendiğinde, hastanın görüntü serisindeki ana serebral arter bölgesini oluşturan damarların tüm piksellere oranı yaklaşık %0.05 olduğu tespit edilmiştir. Bu nedenle bu bölgeyi oluşturan damarların etiketlenmesi için, Çizelge 4.1’de gösterilen Philips marka Intera model MR cihazında yaklaşık olarak 152 846 adet vokselle elemanının etiketlenmesi gerekmektedir. Bu durum ise manuel olarak etiketleme açısından maliyetli ve deneyimli radyolog ihtiyacı olduğundan ağır iş yükü oluşturmaktadır.

Tez çalışması kapsamında, veri etiketleme sürecini hızlandırmak amacıyla Bölüm 4.1’deki görüntü işleme algoritması kullanılmıştır. Bu sayede, 40 farklı hastaya ait MR kesit görüntüleri hızlı bir şekilde etiketlenmiştir. İkinci aşamada hastalara ait görüntü işleme algoritması vasıtasıyla etiketlenen bu görüntüler 3D-Slicer uygulamasında incelenmiştir. İnceleme sırasında, görüntü işleme algoritması tarafından damar olmayan bölümlerdeki yanlış etiketler ve ana serebral arter dışındaki damar bölümleri Slicer uygulaması içerisinde yer alan interaktif silme işlemi vasıtasıyla manuel bir şekilde kaldırılmıştır [76]. Bu işlem sonucu Resim 4.25 üzerinde örnek bir hasta da aşağıdaki gibi gösterilmektedir;




Resim 4.24. Görüntü işleme algoritma çıktısı




Resim 4.25. Ana serebral arterler dışındaki bölümlerin silinmesiyle oluşan çıktı görüntüsü

Yukarıdaki şekil üzerinde yer alan hastanın üç boyutlu damar segmentasyon sonucunda görüleceği üzere ana serebral arter bölgesinden uzaklaştıkça damarlarda incelmeler meydana gelmektedir. Damardaki incelmeler kan akışını doğrudan etkilediğinden görüntü işleme algoritması içerisinde yer alan Hesse matrisi tabanlı filtrelemenin başarısını doğrudan etkilenmektedir. Bu problemin önüne geçmek amacıyla Slicer uygulamasında yer alan ve içerisinde morfolojik işlemleri barındıran Hollow algoritması kullanılmıştır. Hollow algoritması görüntü işleme yardımıyla segmente edilmiş damar bölümlerindeki her bir voksel elamanı ve çevresine uniform şekilde dağılım gösteren kabuk yerleştirmektedir [76]. Bu kapsamda Resim 4.26’da Hollow algoritma çıktısı gösterilmektedir;




Resim 4.26. Hollow algoritması vasıtasıyla oluşan çıktı görüntüsü

Tez çalışması kapsamında, Hollow algoritmasında kullanılan kabuğun kalınlığı hastaya özgü manuel olarak 0.65 - 0.75 mm arasında seçilmektedir. Bu sayede ana serebral arter bölgesi merkezinden uzaklaştıkça damarların daha doğru bölütlenme işlemi sağlanmıştır. Geliştirilen bu teknik vasıtasıyla farklı hastalara ait çıktılar aşağıda gösterilmektedir;



Resim 4.27. Hollow algoritması vasıtasıyla oluşan çıktı görüntüsü




Resim 4.28. Hollow algoritması vasıtasıyla oluşan çıktı görüntüsü

Bu yöntem kullanılarak 40 farklı hastaya ait kesit görüntüleri hızlı bir şekilde etiketlenmiştir. Oluşturulan veri seti, toplamda 6,500 etiketlenmiş görüntü serisinden oluşmaktadır. Damar segmentasyonu konusunda yapılan literatür araştırmalarında, herkesin erişimine açık herhangi bir etiketli veri seti ile karşılaşılmamıştır. Bu tez çalışması ile damar segmentasyon alanında herkesin erişimine açık bir şekilde kullanılabilecek veri seti de üretilmiş olacaktır. Böylece medikal alanda anevrizma, damar bölütlenmesi gibi problemlerde derin öğrenme tekniklerinin başlangıç ağırlıkları oluşturmasında faydalanabilecektir.


Serebral arterler için etiketli veri seti oluşturulması

Gerçekleştirilmiş olan derin öğrenme tabanlı ikinci yaklaşımda ise radyologlar tarafından incelenmek istenen ana serebral arterlerin yanı sıra bazı kılcal damarlara ve kulak çevresindeki istenmeyen damar bölümlerinin ortadan kaldırılmasına odaklanılmıştır. Bu kapsamda 1 adet Philips Intera ve 2 adet Siemens Skyra cihazından elde edilmiş 3 farklı hastaya ait toplamda 500 adet kesit görüntüsünün etiketleme işlemi yapılmıştır. Etiketleme işleminde görüntü işleme algoritması vasıtasıyla çıktılar, ITK-SNAP uygulaması vasıtasıyla tüm damarlar etiketlenecek şekilde manuel olarak üstünden geçilmiştir [77].


Etiketleme işlemi sırasında beyin bölgesini kapsayan kafatası kemiğinin 10 milimetre geri mesafesinden başlayarak beyin merkezine doğru yer alan damarların etiketlenmesi yapılmıştır. Bunun temel nedeni kemik çevresinde yer alan damarlar üzerinde meydana gelen artefakt oluşum etkisinden kaynaklanmaktadır. Bu kapsamda, Philips Intera cihaza ait manuel etiketlenmiş kesit görüntüleri aşağıda gösterilmiştir;



Resim 4.29. Philips Intera cihazına ait etiketlenmiş kesit görüntüleri




Resim 4.30. Siemens Skyra cihazına ait etiketlenmiş kesit görüntüleri




Resim 4.31. Siemens Skyra cihazına ait etiketlenmiş kesit görüntüleri

Yukarıdaki resimlerden gösterilen görüntüler, Siemens marka Skyra model MRG cihazında farklı hastalardan elde edilmiş görüntülerin etiketlenmiş halini göstermektedir. Kesit görüntüler görsel açıdan tek başına damarsal yapıları aktif bir şekilde ifade edememektedir. Bu kapsamda hacim oluşturma tekniği vasıtasıyla üç boyutlu etiketlenmiş segmentasyon çıktıları görsel açıdan damar yapısının incelenmesini kolaylaştırmaktadır. Böylece yanlış etiketleme gibi durumlar kolayca tespit edilerek üzerinde kolayca güncellemeler yapılabilmektedir.


Aşağıdaki resimlerde Siemens marka Skyra model 3T gücündeki MRA cihazı tarafından elde edilmiş hastaya ait görüntülerin, manuel olarak etiketlenerek oluşturduğu üç boyutlu çıktı görüntüleri gösterilmektedir;



Resim 4.32. Siemens Skyra cihaz ilk hastaya ait etiketlenmiş 3D görüntü




Resim 4.33. Siemens Skyra cihaz ilk hastaya ait etiketlenmiş 3D görüntü




Resim 4.34. Siemens Skyra cihaz ilk hastaya ait etiketlenmiş 3D görüntü


Üç boyutlu çıktıları gösterilen hastaya ait veri seti toplamda 652 x 768 çözünürlükte 168 adet kesit görüntüsünden oluşmaktadır. Çekim yapılan MR cihazı içerisinde pikseller arası boşluk 0.27mm x 0.27mm x 0.5mm şeklindedir. Siemens marka Skyra model cihaz tarafından ikinci hastaya ait görüntüler aşağıda gösterilmektedir;



Resim 4.35. Siemens Skyra cihaz ikinci hastaya ait etiketlenmiş 3D görüntü




Resim 4.36. Siemens Skyra cihaz ikinci hastaya ait etiketlenmiş 3D görüntü



Resim 4.37. Siemens Skyra cihaz ikinci hastaya ait etiketlenmiş 3D görüntü

Yukarıdaki resimlerde gösterilen hastaya ait veri seti toplamda 135 adet kesit görüntüsü olmak üzere her bir kesit 720 x 896 görüntü çözünürlüğünden meydana gelmektedir. Çekim yapılan MR cihazı içerisinde pikseller arası boşluk 0.23mm x 0.23mm x 0.7mm şeklindedir.

Philips marka Intera model 3 Tesla gücündeki MRA cihazına ait hastanın etiketlenmiş görüntüsünün üç boyutlu çıktısı Resim 4.38’de gösterilmektedir. Görüntündeki hastaya ait veri seti toplamda 140 adet kesit görüntüsü olmak üzere her bir kesit 512 x 512 çözünürlükten meydana gelmektedir. Çekim yapılan MRA cihazı içerisinde pikseller arası boşluk 0.41mm x 0.41mm x 0.55mm şeklindedir.




Resim 4.38. Philips Intera cihaz üçüncü hastaya ait etiketlenmiş 3D görüntü

Gerçekleştirilen çalışma kapsamında, görüntü işleme algoritması vasıtasıyla elde edilen çıktılar bir önceki sayfalardaki görsellerde gösterildiği gibi manuel olarak etiketleme işlemi gerçekleştirilmiştir. Bu sayede toplamda 3 hastaya ait 500 adet kesit görüntüsü içeren görüntülerin etiketleme işlemi yapılarak eğitim veri seti hazırlanmıştır.

4.3.2. Yapay zeka modellerinin eğitim hazırlıkları

Bu bölüm içerisinde, derin öğrenme tabanlı ESA mimarilerinin eğitim süreci için yapılan hazırlıklardan bahsedilmektedir. Öncelikle, veri seti üzerinde gerçekleştirilen ön işlemler, yani görüntülerin ölçeklendirilmesi ve normalizasyon işlemleri anlatılmaktadır. İlerleyen kısımlarda, yapay zeka modeli için ihtiyaç duyulan yitim fonksiyonları ve optimizasyon teknikleri hakkında bilgi verilmektedir. Bu hazırlıkların doğru bir şekilde yapılması, eğitim sürecinin daha verimli ve başarılı geçmesine katkı sağlamaktadır.

Bu kapsamda, bölüm içerisinde gerçekleştirilecek olan algoritmalara ait akış diyagramı Şekil 4.40'da gösterilmektedir;




Şekil 4.4. Derin öğrenme tabanlı sistem için akış diyagramı

Veri seti ön işlem adımlarının gerçekleştirilmesi

Gerçekleştirilen çalışma kapsamında, eğitim işleminin verimliliği açısından ilk aşamada veri seti üzerinde çeşitli ön işlem adımlarının uygulanması gerekmektedir. Bu kapsamda ilk olarak veri seti içerisinde farklı marka ve modellere ait MRA cihazlarından elde edilmiş kesit görüntüleri üzerine odaklanılmıştır. Her bir kesit görüntüsü içerisindeki damar parlaklık değerleri MRA cihazı ve hastalara göre farklılık göstermektedir. Bu durum, derin öğrenme tekniklerinin eğitim aşamasında optimizasyon ve başarılarını doğrudan etkilemektedir.


Makine öğrenmesinin alt kümesi olan derin öğrenme tekniklerinin damar segmentasyon problemi üzerinde yüksek başarı skor değerleri elde edebilmek amacıyla veri seti üzerinde standardizasyon işleminin uygulanması gerekmektedir. Standardizasyon işlemi vasıtasıyla her bir hastaya ait kesit görüntüleri benzer uzaya dönüştürülerek farklı MRA cihazlarının oluşturduğu farklı dağılımların önüne geçilmektedir. Bu kapsamda MRA görüntülerinde sıklıkla kullanılan Nyúl ve Udupa normalizasyon tekniği kullanılmıştır. Bu tekniğin ilk aşamasında hastalara ait MRA kesit görüntüleri kullanarak tüm veri setini tanımlayan yüzde birlik histogram dağılım değerleri elde edilmektedir. İkinci aşamada ise bu yüzde birlik histogram dağılım değerleri, her bir hasta verisinde kullanılarak tüm veri seti için benzer parlaklık dağılım değerler aralığı elde edilmektedir [78]. Resim 4.39 üzerinde sol taraftaki kesit ham MRA görüntüsünü temsil ederken sağ taraftaki görüntü ise Nyúl ve Udupa normalizasyon tekniğinin çıktısını göstermektedir.



Resim 4 39. Orijinal ve normalizasyon tekniğinin çıktı görüntüleri

Evrişimsel sinir ağı tabanlı derin öğrenme mimarilerinin verimli bir şekilde eğitimi işlemi için model girişlerine statik boyutta giriş görüntüsünün sağlanması gerekmektedir. Tez çalışması kapsamında oluşturulan veri seti içerisinde farklı marka ve modelde MRA cihazları barındırdığından hastalara ait farklı çözünürlükte kesit görüntüleri oluşmaktadır. Bu kapsamda, MRA görüntülerinde parlaklık anlamında standardizasyon sağlandığı gibi verimli bir şekilde eğitim işleminin gerçekleştirilebilmesi için çözünürlük anlamında da standardizasyonunun sağlanması gerekmektedir.

Çözünürlük anlamında standardizasyon sağlanabilmesi için Çizelge 4.1 içerisinde yer alan veri seti detaylı bir şekilde incelenmiştir. İncelemeler sırasında MRA cihazlarında görüntünün genişlik ve yükseklik kısımlarının oluşturulmasında kullanılan algılayıcıların piksel genişlikleri birbirine yakın bir şekilde yerleştiğinden kesit görüntüler benzer ölçeklerde yer almaktadır. Bu sebeple görüntüler üzerinde herhangi bir ölçeklendirme veya yeniden örnekleme işlemine ihtiyaç duyulmamıştır. Veri seti incelemeleri sonucunda 800 x 800 çözünürlüğün tüm veriler için ilgili beyin bölgesini kapsamada yeterli olacağı görülmüş ve bu kapsamda tüm hastalara ait iki boyutlu kesit görüntüler 800 x 800 piksel çözünürlüğüne sığdırılmıştır. Resim 4.40 üzerinde çözünürlük anlamında standardizasyon işlemi için en belirgin olan Philips marka Intera modelde 512 x 512 çözünürlükte kesit görüntüsü seçilmiş olup, doldurma işlemi vasıtasıyla elde edilen standart formatta yeni görüntü gösterilmektedir. Bu görüntüler ardından modele verilirken 400 x 400 olacak şekilde boyut küçültme işlemi yapılmaktadır.



Resim 4.40. Çözünürlük standardizasyon işleminin gösterilmesi

Model yitim fonksiyonu ve optimizasyon algoritması

Yapay zekâ algoritmalarında kullanılan yitim fonksiyonları, eğitim işlemi sırasında gerçekleştirilen modelin yaptığı tahmin çıktılarının, gerçek değerlerden ne kadar uzaklaştığına dair ölçüsünü yansıtmaktadır. Yapılan eğitimin amacı, modelin tahminleri ile gerçek değerler arasındaki farkı minimize etmektir. Yitim fonksiyonu ise, genellikle geriye doğru yayılım algoritması sırasında kullanılarak, modelin içerdiği parametrelerin güncellemesini sağlamaktadır.

Yitim fonksiyonları, problemin türüne ve kullanılan modelin yapısına bağlı olarak farklılık gösterebilmektedir. Örneğin, sınıflandırma problemleri için genellikle çapraz entropi(Cross Entropy) yitim fonksiyonu kullanılmaktadır. Bu fonksiyon temelde, tahmin edilen sınıf dağılımını gerçek sınıf dağılımıyla karşılaştırarak oluşan hatayı hesaplamaktadır. Kısaca, doğru tahminlerde hatanın az, yanlış tahminlerde hatanın yüksek olması beklenmektedir. Bu kapsamda, yitim fonksiyonları ayrı ayrı kullanıldığı gibi, probleme özgü farklı yitim fonksiyonlarının bir araya getirilmesiyle oluşturulmuş birleşik yitim fonksiyonları da kullanılabilmektedir.


Gerçekleştirilen tez çalışması kapsamında, SVH tespiti amacıyla damar problemlerinin bölütlenmesi piksel seviyesinde sınıflandırma problemi olarak kabul edilmektedir. Bu kapsamda, yitim fonksiyonu olarak ikili çapraz entropi(Binary Cross Entropy) ve Dice yitim fonksiyonlarının bir araya gelerek oluşturduğu birleşik yitim fonksiyonu kullanılmıştır. İkili çapraz entropi fonksiyonu olasılık dağılım tabanlı özelliğini kullanarak yitim değerini minimize edilirken, eş zamanlı olarak Dice yitim fonksiyonunun da bölge tabanlı kesişim oranına bakarak dengesiz veri setlerinde yitim fonksiyonunu istikrarlı hale getirmektedir. Bu kapsamda yeni birleşik yitim fonksiyonu aşağıdaki eşitliklerdeki gibidir;

$$L_{BCE} = \frac{1}{N} \sum_{i=0}^N y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (4.16)$$

$$L_{Dice} = \frac{2 * \Sigma y_{true} * \Sigma y_{pred}}{\Sigma y_{true}^2 + \Sigma y_{pred}^2} \quad (4.17)$$

$$Loss = L_{BCE} + L_{Dice} \quad (4.18)$$

Derin öğrenme algoritmalarında, optimizasyon algoritmaları vasıtasıyla geri yayılım algoritması tarafından üretilen türev değerlerine bağlı olarak ağırlık değerlerinin güncellenme işlemi gerçekleşmektedir. Bu kapsamda probleme uygun olarak optimizasyon algoritmalarının seçimi büyük önem taşımaktadır. Çalışma içerisinde literatürde derin öğrenme alanında sıklıkla kullanılan Adam optimizasyon algoritması kullanılmaktadır. Bu teknik vasıtasıyla, her bir yığın içerisinde geri yayılım algoritması tarafından hesaplanan ortalama türev değerleri ile kendinden önce gelen yığınlardaki ortalama türev değerlerinin üstel ağırlıklı ortalaması alınarak mimari içerisinde yer alan ağırlık parametrelerinin güncellenmesi sağlanmaktadır. Bu nedenle Adam optimizasyon algoritması, RMSProp ve Momentum algoritmasının birleştirilmesiyle oluştuğundan yığın içerisinde büyük yada küçük şekilde gelen ortalama türev değerlerinden etkilenmeden yitim fonksiyon değerinin global minimuma ulaşılmasına yardımcı olmaktadır [79]. Bu kapsamda optimizasyon algoritmaları vasıtasıyla oluşan yitim fonksiyonu plato eğrisi aşağıda gösterilmektedir;



Şekil 4.5. Yitim fonksiyonu plato eğrisi

Derin öğrenme modellerinde öğrenme hızı ya da öğrenme oranı(Learning Rate), geliştirilen modelin eğitimi sırasında ağırlık güncellemelerinin yapılmasında kullanılan bir katsayıdır. Bu kapsamda deneysel olarak başlangıç aşamasında öğrenme kat sayısı 0.001 seçilerek yitim fonksiyonun ilk kademelerde salınım yapmasının önüne geçilmiştir. Eğitim süresi boyunca ise yitim fonksiyonunun global minimuma yaklaştığı esnada ağırlık değerlerinin büyük bir oranda güncellenmesinin önüne geçebilmek amacıyla öğrenme kat sayısı değeri her 5000 yığında 0.95 oranda azalacak şekilde üstel biçimde azaltılmıştır.

Eğitim konfigürasyonu

Derin öğrenme modellerinin eğitim işlemi sırasında Intel 10.nesil i7-10750 h işlemci, 128 GB ram ve NVIDIA RTX 3090 ekran kartından meydana gelen bilgisayar üzerinde gerçekleştirilmiştir. Geliştirilen tüm kodlar Pytorch 1.13.1 sürüm üzerinde geliştirilmiş olmakla beraber eğitim aşamasında GPU üzerindeki birimlerden faydalanabilmek için NVIDIA CUDA 11.7 sürümü kullanılmıştır.

4.3.3. Derin öğrenme tabanlı ana serebral arterlerin segmentasyonu

Gerçekleştirilen tez çalışmasının ilk bölümünde, ana serebral arter bölgesinde yer alan damarların bölütleme işlemi üzerine odaklanılmıştır. Bu kapsamda, derin öğrenme tabanlı medikal görüntüleme uygulamalarında aktif olarak kullanılan UNet, ResUNet, ResUNet++ ve TransUNet mimarileri damar segmentasyon problemine yönelik uyarlanmıştır. Bu kapsamda kullanılan mimarilere ait detaylı parametre bilgileri Çizelge 4.3’de sunulmaktadır;

Çizelge 4.3. Eğitim mimarilerinin parametre bilgileri

	UNet	ResUNet	ResUNet++	TransUNet
Görüntü Boyutu	400 × 400	400 × 400	400 × 400	400x400
Öğrenme Kat Sayısı	1×10^{-3}	1×10^{-3}	1×10^{-3}	1×10^{-3}
Yığın Boyutu	24	24	24	24
Epok Sayısı	45	45	45	45
Optimizer	Adam	Adam	Adam	Adam
Attention Sayısı	-	-	-	12
Transformer Sayısı	-	-	-	12
Patch Boyutu	-	-	-	5
Gömme Boyutu	-	-	-	768
Saklı Boyutu	-	-	-	2048
Parametre Sayısı	7,762,465	13,167,969	4,053,201	116,098,801


Çizelge 4.3’ de görüleceği üzere, UNet, ResUNet, ResUNet++ mimarileri genellikle ESA’dan meydana geldiğinden benzer yapıda özellik göstermektedir. TransUNet mimarisi ise dil işleme alanında kullanılan mimariler gibi içerisinde barındırdığı dönüştürücüler sayesinde aktif olarak YSA kullanıldığından diğer mimarilere kıyasla daha yüksek parametre sayısına sahiptir. Bunun temel nedeni ESA yapısından kaynaklı içerisinde

ağırlıkların paylaşım özelliği gerçekleşirken, bu durum YSA mimarilerinde gerçekleşmemektedir.


Parametre sayısının artması, geliştirilen mimarinin eğitim maliyetini artırmış gibi gözükse de, modern derin öğrenme kütüphaneleri vasıtasıyla geliştirilen YSA'nın GPU üzerinde bütünleşik çalıştığından eğitim işlemi hızlı ve başarılı bir şekilde gerçekleşebilmektedir. Bu durum, çalışma kapsamında dört farklı modelin ve içerdikleri farklı yaklaşımların birbirleriyle karşılaştırılmasını ve problem için en uygun mimarinin seçilmesini mümkün kıldırılmaktadır.

Derin öğrenme tabanlı eğitim işlemi ve sonuçların değerlendirilmesi

Gerçekleştirilen tez çalışması kapsamında UNet, ResUNet, ResUNet++, TransUNet mimarileri, toplamda 40 hasta üzerinden elde edilen 6312 adet kesit görüntüsü kullanılarak eğitilmiştir. Eğitim işlemi sırasında 5052 adet kesit görüntüsü kullanılırken, kalan 1262 adet kesit görüntüsü test işlemi için ayrılmıştır. Mimarilerin adil bir şekilde karşılaştırılması amacıyla UNet, ResUNet ve ResUNet++ mimarilerinin kodlayıcı ve kod çözücü kısımlarında yer alan ESA'dan meydana gelen blok sayıları eşit seçilmiştir. UNet ve ResUNet mimarilerinde her blokta kullanılan filtre sayıları eşit seçilirken, ResUNet++ mimarisinde işlem maliyetini azaltmak amacıyla her bloktaki filtre sayısı diğer mimarilere kıyasla yarısı kadar azaltılmıştır. Bu kapsamda 4 farklı mimarinin eğitim işlemi sırasındaki yitim fonksiyon değerleri Şekil 4.4'te gösterilmektedir;



Şekil 4.6. Geliştirilen mimarilerin yitim fonksiyon değerlerinin karşılaştırılması



Şekil 4.7. Geliştirilen mimarilerin Jaccard indeks değerlerinin karşılaştırılması


ResUNet++ mimarisi Şekil 4.14 incelendiğinde diğer mimarilere kıyasla daha erken aşamalarda öğrenme işlemi gerçekleştiği gözlemlenmiştir. Bu duruma ilave olarak Şekil 4.5’de ise her bir iterasyondaki validasyon seti üzerinde Jaccard indeks değeri gösterilmektedir. Değerler üzerinde görüleceği üzere öğrenme işlemi beraberinde genelleme başarısı da getirdiği ve Jaccard indeks değeri açısından en büyük skorun yine ResUNet++ mimarisinde elde edildiği gözlemlenmiştir. Bu kapsamda Çizelge 4.3’de mimarilerin farklı metrikler açısından test verisi üzerinde elde ettiği başarı skorları gösterilmektedir;

Çizelge 4.4. Test verisi üzerinde modellerin başarılarının karşılaştırılması


	UNet	ResUNet	ResUNet++	TransUNet
Piksel Doğruluğu	0.9994	0.9994	0.9995	0.9994
Ortalama Jaccard İndeksi	0.9030	0.9072	0.9168	0.8960
Duyarlılık	0.9077	0.8940	0.9008	0.8908
Kesinlik	0.8805	0.9048	0.9193	0.8935
F Skor	0.8921	0.8968	0.9093	0.8893
Hesap Süresi(us)	0.4580	0.7771	0.7480	0.5461

Çizelge 4.3 üzerinde açıkça görüleceği üzere, duyarlılık metrikleri dışındaki tüm metriklerde en iyi segmentasyon sonuçları ResUNet++ mimarisinde elde edilmiştir. UNet, ResUNet ve TransUNet mimarileri piksel doğruluğu açısından yeterli olmaların rağmen, mIoU, hassasiyet ve F skoru metrikleri açısından ResUNet++ mimarisinin gerisinde kalmaktadır. Özellikle UNet mimarisindeki düşük kesinlik değeri, damar segmentasyon probleminde yanlış damarların etiketlenmesine neden olmaktadır ve bu durum hatalı segmentasyon sonuçları üretmektedir. TransUNet mimarisindeki düşük duyarlılık değeri ise damar bölümlerinin belirli parçalarının zayıf bir şekilde bölütlenmesi işlemine neden olmaktadır.


Gerçekleştirilen çalışma kapsamında ResUNet++ mimarisi ise diğer mimarilere kıyasla daha yüksek başarı değerleriyle ve daha istikrarlı sonuçlar ürettiği gözlemlenmiştir. Bu nedenle ResUNet++ mimarisinin, hastalara ait çeşitli kesit görüntülerinde ürettiği segmentasyon çıktıları aşağıdaki şekillerde gösterilmektedir. Şekiller içerisinde sol taraftaki kesit görüntüsü tarafımızca görüntü işleme metodu ve ITK-SNAP uygulaması vasıtasıyla manuel bir şekilde etiketlenmiş görüntüleri simgelerken sağ taraftaki kesit görüntüsü ise geliştirilen model tarafından yapılan tahmin çıktısını göstermektedir;




Resim 4.41. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı




Resim 4.42. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı



Resim 4.43. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı




Resim 4.44. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı




Resim 4.45. Etiketlenmiş görüntü ve ResUNet++ modelinin tahmin çıktısı


Yukarıdaki şekiller, hastalara ait kesit görüntülerindeki modelin başarısını göstermektedir. Bunun yanı sıra, farklı hastalara ait oluşturulmuş üç boyutlu segmentasyon sonuçları da ilerleyen şekillerde gösterilmektedir. Şekillerdeki mavi renk, etiketlenmiş görüntüyü temsil ederken, kırmızı renkli kısımlar ise modelin tahmin sonuçlarını göstermektedir. İki renk bir araya geldiğinde oluşan görüntü ise, geliştirilen modelin tahmin çıktısı ile etiketlenmiş görüntünün çıktısını karşılaştırmaktadır.



Resim 4.46. Siemens marka Skyra model hastaya ait etiketlenmiş görüntü




Resim 4.47. Siemens marka Skyra model hastaya ait ResUNet++ tahmin çıktısı




Resim 4.48. Siemens marka Skyra model hastaya ait çıktıların karşılaştırılması


Aşağıdaki şekillerde Siemens marka Verio model hastaya ait üç boyutlu etiketlenmiş görüntü ve model tahmin çıktıları gösterilmektedir;



Resim 4.49. Siemens marka Verio model hastaya ait etiketlenmiş görüntü




Resim 4.50. Siemens marka Verio model hastaya ait ResUNet++ tahmin çıktısı




Resim 4.51. Siemens marka Skyra model hastaya ait çıktıların karşılaştırılması


Aşağıdaki şekillerde ise Philips marka Intera model hastaya ait üç boyutlu etiketlenmiş görüntü ve model tahmin çıktıları gösterilmektedir.



Resim 4.52. Philips marka Intera model hastaya ait etiketlenmiş görüntü



Resim 4.53. Philips marka Intera model hastaya ait ResUNet++ tahmin çıktısı



Resim 4.54. Philips marka Intera model hastaya ait çıktıların karşılaştırılması

4.3.4. Derin öğrenme tabanlı serebral arterlerin segmentasyonu

Tez çalışmasının ikinci bölümünde, sadece ana serebral arter damarlarının yanı sıra aynı zamanda diğer serebral arterlerin de bölütleme işlemi üzerinde durulmuştur. Bu kapsamda geliştirilen yaklaşımda, artefakt oluşumu sebebiyle beyin bölgesindeki korteks yüzeydeki damarlar hariç, beyindeki tüm serebral arterlere odaklanılmıştır. Bu sayede, damarlar üzerinde meydana gelecek herhangi bir hastalığın hızlı bir şekilde teşhis edilmesi amaçlanmaktadır.


Gerçekleştirilen çalışmanın ikinci bölümünde, beyin bölgesinde yer alan damar bölümlerinin segmentasyonu probleminde derin öğrenme mimarisi olarak ResUNet++ mimarisi seçilmiştir. Bunun temel nedeni, ResUNet++ mimarisi ana arter damarlarının segmentasyonunda diğer mimarilere kıyasla daha başarılı sonuçlar elde ettiği bölüm 4.3.3.1 içerisinde kanıtlanmıştır. Bu nedenle çalışma içerisinde kullanılan modele ait parametre bilgileri aşağıdaki tabloda gösterilmektedir;

Çizelge 4.5. Eğitim mimarisinin parametre bilgileri

	ResUNet++
Giriş Görüntü Boyutu	400×400
Her Bloktaki Filtre Sayısı	16, 32, 64, 128, 256
Öğrenme Kat Sayısı	1×10^{-3}
Yığın Boyutu	24
Epok Sayısı	20
Optimizör	Adam
Parametre Sayısı	4,053,201

Gerçekleştirilen derin öğrenme tabanlı mimarinin eğitim işlemleri sırasında kullanılacak veri seti toplamda 3 farklı hastalara ait kesit görüntülerinden meydana gelmektedir. Kullanılan hastaların verileri incelendiğinde, iki farklı hastaya ait görüntüler Siemens marka Skyra model cihazda çekilirken, üçüncü hastanın görüntüleri ise Philips marka Intera model MRA cihazıyla kaydedilmiştir. Eğitim işlemi sırasında çapraz doğrulama yöntemi kullanılarak, test aşamasında kullanılacak verilerin eğitim aşamasında kullanılacak verilerden farklı olması sağlanmıştır. Bu sayede, modelin farklı hastalar üzerindeki genelleme başarısı adil bir şekilde karşılaştırılmış olup başarılı bir şekilde eğitim işlemi gerçekleştirilmiştir.

Bu kapsamda, bölüm içerisinde gerçekleştirilecek olan algoritmalara ait akış diyagramı Şekil 4.56'da gösterilmektedir;



Şekil 4.8. Derin öğrenme tabanlı sistem için akış diyagramı

Derin öğrenme tabanlı eğitim işlemi ve sonuçların değerlendirilmesi


Eğitim işlemi sırasında, modelin içerdiği ağırlıkların rastgele bir şekilde başlaması yerine, ana serebral arterlerin bölütlenmesi işleminde eğitilmiş ağırlıklar transfer edilerek modelin

eğitim işlemi gerçekleştirilmiştir. Eğitim sırasında çapraz doğrulama tekniği kullanılmıştır. Bu sayede toplamda 3 farklı hastaya ait kesit görüntüleri her bir hasta test setinde olacak şekilde 3 farklı eğitim işlemi gerçekleştirilmiştir. Böylece eğitim aşamasında test edilen hastaya ait herhangi bir kesit görüntüsü eğitim seti içerisinde yer almamaktadır. Bu kapsamda yapılan eğitime ait metrik sonuç değerleri Çizelge 4.5’de verilmiştir;


Çizelge 4.6. Test verisi üzerinde modellerin başarılarının karşılaştırılması

	Marka	Model	Piksel Doğruluğu	Ortalama Jaccard İndeksi	Kesinlik	Duyarlılık	F Skor
Hasta 1	Siemens	Skyra	0.9984	0.8861	0.8751	0.8697	0.8700
Hasta 2	Siemens	Skyra	0.9986	0.8851	0.9180	0.8321	0.8654
Hasta 3	Philips	Intera	0.9992	0.8610	0.9020	0.7915	0.8267


Eğitim sonucunda elde edilmiş her bir hasta için, ayrı ayrı üretilen çapraz doğrulanmış modellerin iki boyutlu kesit test görüntülerinde oluşturdukları ResUNet++ modelinin tahmin çıktıları elde edilmiştir. Bu kapsamda Philips Intera makinesinde çekim yapılmış bir hastanın 135 adet kesit görüntüsü içerisinde modelin yaptığı bazı tahminler aşağıdaki şekillerde gösterilmiştir. Şekiller içerisinde sol taraftaki kesit görüntüsü tarafımızca etiketlenmiş görüntüleri içerirken sağ taraftakiler modelin tahminini göstermektedir.




Resim 4.55. Philips Intera cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı



Resim 4.56. Philips Intera cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.57. Philips Intera cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.58. Philips Intera cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı


Benzer şekilde Siemens marka Skyra model MR makinesinde çekim yapılmış ikinci hastaya ait kesit görüntülerinde modelin yaptığı tahmin çıktıları aşağıdaki şekillerde gösterilmektedir. Şekiller içerisinde sol taraftaki kesit görüntüsü tarafımızca etiketlenmiş görüntüleri simgelerken sağ tarafta yer alan görüntüler ise modelin tahmin çıktılarını göstermektedir.




Resim 4.59. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.60. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı



Resim 4.61. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.62. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.63. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı


Son olarak Siemens marka Skyra model MR makinesinde çekim yapılmış üçüncü hastaya ait kesit görüntülerinde modelin yaptığı tahmin çıktıları aşağıdaki şekillerde gösterilmektedir. Şekiller içerisinde sol taraftaki kesit görüntüsü tarafımızca etiketlenmiş görüntüleri simgelerken sağ tarafta yer alan görüntüler ise modelin tahmin çıktılarını göstermektedir.




Resim 4.64. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.65. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı



Resim 4.66. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.67. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı




Resim 4.68. Siemens Skyra cihaza ait hasta kesit görüntüsü ve ResUNet++ tahmin çıktısı


Bir önceki sayfalarda gösterilen şekiller, çapraz doğrulama kullanılarak hastalara ait kesit görüntülerindeki modellerin başarısını göstermektedir. Bunun yanı sıra, farklı hastalara ait iki boyutlu tahmin çıktıların birleştirilerek oluşturduğu üç boyutlu segmentasyon çıktılarını incelemek daha anlaşılır olacaktır. Bu kapsamda, Siemens marka Skyra model MR cihazında çekilmiş hastaya ait üç boyutlu etiketlenmiş ve model tahmin çıktıları aşağıdaki şekillerde gösterilmektedir. Mavi renkli şekiller etiketlenmiş görüntüyü temsil ederken kırmızı renkli görüntüler ise ResUNet++ tahmin çıktısını göstermektedir.




Resim 4.69. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü




Resim 4.70. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü




Resim 4.71. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü



Resim 4.72. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü




Resim 4.73. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü




Resim 4.74. Siemens Skyra cihaza ait model ResUNet++ çıktı görüntüsü


İkinci olarak Siemens Skyra marka Manyetik Rezonans Görüntüleme cihazında kesit görüntüleri elde edilmiş hastaya ait gerçekleştirilen modelin tahmin sonuçlarını içermektedir. Bu kapsamda hastaya ait üç boyutlu etiketlenmiş ve model tahmin çıktı görüntüleri aşağıdaki şekillerde gösterilmektedir;




Resim 4.75. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü




Resim 4.76. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü




Resim 4.77. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü



Resim 4.78. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü




Resim 4.79. Siemens Skyra cihaza ait etiketlenmiş hasta çıktı görüntüsü.




Resim 4.80. Siemens Skyra cihaza ait ResUNet++ tahmin çıktı görüntüsü


Son olarak Philips marka Intera model Manyetik Rezonans Görüntüleme cihazında kesit görüntüleri elde edilmiş hastaya ait gerçekleştirilen modelin tahmin sonuçlarını içermektedir. Bu kapsamda hastaya ait üç boyutlu etiketlenmiş ve model tahmin çıktı görüntüleri aşağıdaki şekillerde gösterilmektedir;




Resim 4.81. Philips Intera cihaza ait etiketlenmiş hasta çıktı görüntüsü




Resim 4.82. Philips Intera cihaza ait ResUNet++ tahmin çıktı görüntüsü




Resim 4.83. Philips Intera cihaza ait etiketlenmiş hasta çıktı görüntüsü



Resim 4.84. Philips Intera cihaza ait ResUNet++ tahmin çıktı görüntüsü



Resim 4.85. Philips Intera cihaza ait etiketlenmiş hasta çıktı görüntüsü



Resim 4.86. Philips Intera cihaza ait ResUNet++ tahmin çıktı görüntüsü



5. TARTIŞMA

Gerçekleştirilen tez çalışması doğrultusunda, TransUNet mimarisi diğer tekniklere kıyasla en güncel görüntü dönüştürücüleri(Vision Transformers) teknolojilerini içermesine rağmen, daha düşük bir başarı sonucu elde etmiştir. Bunun temel nedeni, dönüştürücü tabanlı mimarilerin genellikle yüksek miktarda veri ve güçlü veri artırım teknikleriyle birlikte kullanıldığında başarısının arttığı çeşitli literatür çalışmalarıyla kanıtlanmıştır. Gerçekleştirilen çalışmada ise, sınırlı bir veri seti kullanılmış olması, TransUNet mimarisinin diğer mimarilere kıyasla daha düşük bir başarı skoru elde etmesine neden olmuştur. Böylece, dönüştürücü tabanlı mimarilerin başarılarıyla ilgili daha kapsamlı çalışmaların ve daha fazla veriye dayalı araştırmaların gerekliliğini vurgulamaktadır.

Gerçekleştirilen çalışmanın çıktıları incelendiğinde, konvolüsyon tabanlı mimarilerin damar segmentasyon probleminde dönüştürücü tabanlı mimarilere göre daha iyi bir performans gösterdiği gözlemlenmiştir. Bu durum, konvolüsyon tabanlı mimarilerin daha az veriyle daha kolay öğrenebilme yetenekleri ve genelleme başarılarının yüksek olduğu gözlemlenmiştir. Çalışmamızda, konvolüsyon tabanlı mimarilerden ResUNet++ mimarisinin damar segmentasyonunda en yüksek skoru elde ettiği görülmüştür. Bu sonuçlar, damar segmentasyonu için daha fazla veri elde edilemediği durumlarda, konvolüsyon tabanlı mimarilerin güvenilir bir seçenek olduğunu göstermektedir. Bu duruma ilave olarak yapılan çalışma ResUNet, ResUNet++, TransUNet mimarilerinin damar segmentasyonuna uyarlandığı ilk çalışma özelliği taşımaktadır.

Literatürdeki çalışmalar incelendiğinde damar segmentasyonu problemlerinde kullanılan mimarilere genellikle görüntüler parçalara ayrıldıktan sonra eğitim işlemi yapılmaktadır. Gerçekleştirilen çalışma diğer çalışmalardan farklı olarak hastaya ait tüm iki boyutlu kesit görüntüsü üzerinde eğitim işlemi yapılarak başarısını kanıtlamıştır. Sonuç olarak, çalışma hem serebral arterlerin tamamının hem de ana serebral arterlerin segmentasyonu için farklı mimarilerin başarılarını değerlendirmiştir.



6. SONUÇLAR VE ÖNERİLER

Serebrovasküler hastalıklar, beyni besleyen damar bölümleri üzerinde, kan akışının zayıflaması, durması veya damarların yırtılması sonucunda ciddi beyin hasarlarına sebep olan hastalık grubudur. Bu sebeple serebrovasküler hastalıklar, dünya genelinde ölüm nedenleri arasında üçüncü sırada yer alırken, hastalık sonrasında engelli kalma oranı açısından ilk sırada yer almaktadır. Bu nedenle, beyin damarlarının oluşturduğu vasküler yapının detaylı bir şekilde incelenmesi, erken hastalık teşhisi için büyük önem taşımaktadır. Bu sebeple çalışma kapsamında, erken aşamada SVH teşhisinde kullanılabilecek üç farklı yöntem geliştirilmiştir.

Gerçekleştirilen tez çalışmasının ilk bölümünde, klasik görüntü işleme tabanlı yöntemler kullanılarak beyin bölgesinde yer alan damarların bölütlenmesi sağlanmıştır. Geliştirilen yöntem ilk olarak Hesse matrisleri vasıtasıyla ilgili damar bölümlerini çıkarmaktadır. İkinci aşamada ise bağlı bileşenlerin etiketlenmesi algoritmasından faydalanılarak belirli voksel boyutundan küçük olan bölümlerin silinmesi sağlanmıştır. Son aşamada ise bölge büyütme algoritması kullanılarak damar bölümlerindeki bölütleme başarısı artırılmaktadır. Görüntü işleme tabanlı sonuçlar incelendiğinde damarların büyük bir bölümünü başarılı şekilde segmentasyonunu sağlasa da içerisinde kullanılan algoritmaların parametrik oluşu sebebiyle genelleme başarısının düşük olmasına sebep olmaktadır. Bu nedenle farklı Manyetik Rezonans Anjiyografi cihazlarında farklı hastalara ait görüntülerde damar olmayan bölümlerin segmentasyonuna veya damar olan bölümlerin eksik bir şekilde bölütleme işlemine neden olabilmektedir.

Görüntü işleme tabanlı geliştirilen yöntemlerdeki eksiklikler son yıllarda popüler olan derin öğrenme yaklaşımlarının damar bölütleme problemine uygulanmasını doğurmuştur. Derin öğrenme tabanlı yöntemlerin uygulanabilirliği için öncelikle etiketli bir şekilde veri setinin oluşturulması gerekmektedir. Medikal görüntüler incelendiğinde milyonlarca voksel meydana gelmektedir. Bu nedenle sıfırdan etiketli bir veri setinin oluşturulması zaman ve deneyimli radyolog açısından maliyetli olmaktadır. Süreci hızlandırmak amacıyla görüntü işleme tabanlı geliştirilen teknikler kullanılarak hızlı bir şekilde veri setinin oluşturulması sağlanmıştır. İlerleyen aşamada ise oluşturulan veri seti üzerinde manuel olarak kontrol ve etiketleme işlemleri sağlanarak veri seti oluşturulmuştur.

Gerçekleştirilen tez çalışmasının ikinci bölümünde ana serebral arterlerin segmentasyonu üzerine odaklanılmıştır. Bunun nedeni genellikle, anevrizma gibi çeşitli serebrovasküler hastalıkların birçoğu bu bölge üzerinde yer alan damarlar üzerinde meydana gelmektedir. Bu nedenle bu bölümlerin doğru bir şekilde bölütleme işlemi, hastalık teşhisi için oldukça önem taşımaktadır. Bu kapsamda, medikal problemlerde yaygın olarak kullanılan derin öğrenme mimarileri olan UNet, ResUNet, ResUNet++ ve TransUNet yaklaşımları kullanılarak beyin içerisinde ana serebral arterlerin segmentasyonu başarılı bir şekilde sağlanmıştır. Sonuçlar incelendiğinde %91.68 mIoU değeri ile en yüksek skorun ResUNet++ mimarisinde elde edildiği gözlemlenmiştir.

Çalışmanın son bölümünde ise ana serebral arterlerin yanı sıra diğer damar bölümlerinin de segmentasyonuna odaklanılmıştır. Bu kapsamda ana serebral arterlerin segmentasyonunda en yüksek skor değerlerini elde eden ResUNet++ mimarisi seçilmiştir. Eğitim işlemi sırasında, modelin içerdiği ağırlıkların rastgele bir şekilde başlaması yerine, ana serebral arterlerin bölütlenmesi işleminde eğitilmiş ağırlıklar transfer edilerek üç farklı hastaya ait görüntüler üzerinde çapraz doğrulama yöntemi vasıtasıyla eğitim işlemi gerçekleştirilmiştir. Gerçekleştirilen eğitim sonuçları incelendiğinde Siemens marka Skyra modele ait hasta için %88.61 mIoU değeri elde edilmiştir. Benzer şekilde ikinci hastaya ait Siemens marka Skyra model makine vasıtasıyla elde edilmiş görüntüler incelendiğinde %88.51 mIoU değeri elde edilmiştir. İki hasta içinde ortak olarak merkezden uzaklaştıkça damarlar incelendiğinden ve bu durum görüntüdeki piksel yoğunluk değerlerini düşürdüğünden bazı bölümlerde eksik bölütleme işlemine neden olduğu gözlemlenmiştir.

Üçüncü hastaya ait görüntüler incelendiğinde ise %86.10 mIoU değeri ile diğer iki hastaya nazaran biraz daha düşük başarı skorları ile segmentasyon sonuçları elde edilmiştir. Bunun temel nedeni olarak ağırlık transferi yapılan mimaride kullanılan veri seti içerisinde genellikle Siemens marka MRA cihazlarından elde edilmiş veri setinden meydana gelmektedir. Bu sebeple farklı dağılıma ait Philips marka makinede daha düşük sonuçlara neden olduğu gözlemlenmiştir. Böylece ilerleyen çalışmalarda Philips marka MRA cihazından çekilmiş hastalara ait verilerin eklenerek segmentasyon başarı değerlerinin artırılması planlanmaktadır bu sayede veri seti içerisinde benzer sayıda MRA cihaz çeşitliliği sağlanarak daha verimli ve daha başarılı bir şekilde eğitim işleminin yapılması planlanmaktadır.

Sonuç olarak gerçekleştirilen çalışmalar doğrultusunda görüntü işleme ve derin öğrenme tabanlı yaklaşımlar ile beyin bölgesinde yer alan damarların segmentasyonu başarı bir şekilde gerçekleştirilmiştir. Gerçekleştirilen çalışma içerisinde beyin bölgesinde yer alan damarların uzamsal konumlarından faydalanabilmek amacıyla doğrudan kesit görüntüleri bölümlere ayrılmadan ana görüntü üzerinde çalışılmıştır. Bu nedenle çalışma kapsamında kullanılan derin öğrenme tabanlı mimariler iki boyutlu evrimsel sinir ağlarından meydana gelmektedir. Gelecekteki çalışmalarda, elde edilen bölütlenmiş arter bölümleri için klinik kullanıma daha uygun ve hastalıkların tespitine yardımcı olacak, damarların geometrik muayenesi için hızlı ve etkili yöntemler geliştirmeye odaklanılacaktır.





KAYNAKLAR

1. İnternet: Göncü, T. (2016). Beyin Damar Hastalıkları Serebrovasküler Hastalık. URL <https://turgaygoncu.com.tr/makale/beyin-damar-serebrovaskuler> Son Erişim Tarihi: 24.05.2023.
2. Feigin, V. L., Stark, B. A., Johnson, C. O., Roth, G. A., Bisignano, C., Abady, G. G., ... and Hamidi, S. (2021). Global, regional, and national burden of stroke and its risk factors, 1990–2019: a systematic analysis for the Global Burden of Disease Study 2019. *The Lancet Neurology*, 20(10), 795-820.
3. Hainc, N., Mannil, M., Anagnostakou, V., Alkadhi, H., Blüthgen, C., Wacht, L., ... and Winklhofer, S. (2020). Deep learning based detection of intracranial aneurysms on digital subtraction angiography: a feasibility study. *The Neuroradiology Journal*, 33(4), 311-317.
4. Phellan, R., Peixinho, A., Falcão, A., and Forkert, N. D. (2017). *Vascular segmentation in TOF MRA images of the brain using a deep convolutional neural network*. In 20th International Conference on Medical Image Computing and Computer Assisted Intervention(MICCAI), Québec City, QC, Canada, 39–46.
5. Solomon, C., and Breckon, T. (2011). *Fundamentals of Digital Image Processing: A practical approach with examples in Matlab*. New Jersey, Wiley-Blackwell, 123-129
6. İnternet: Wikipedia. (2023). Hessian Matrix. URL https://en.wikipedia.org/wiki/Hessian_matrix Son Erişim Tarihi: 24.05.2023.
7. Sato, Y., Nakajima, S., Atsumi, H., Koller, T., Gerig, G., Yoshida, S., and Kikinis, R. (1997). *3D multi-scale line filter for segmentation and visualization of curvilinear structures in medical images*. In International Conference on Computer Vision, Virtual Reality, and Robotics in Medicine, Grenoble, FR, 213-222.
8. Frangi, A. F., Niessen, W. J., Vincken, K. L., and Viergever, M. A. (1998). *Multiscale vessel enhancement filtering*. In Medical Image Computing and Computer-Assisted Intervention-MICCAI'98: First International Conference, Cambridge, MA, USA, 130-137.
9. Meijering, E., Jacob, M., Sarria, J. C., Steiner, P., Hirling, H., and Unser, M. (2004). *Neurite tracing in fluorescence microscopy images using ridge filtering and graph searching: principles and validation*. In International Symposium on Biomedical Imaging(ISBI), Arlington, VA, USA, 1219-1222.

10. Jerman, T., Pernuš, F., Likar, B., and Špiclin, Ž. (2016). Enhancement of vascular structures in 3D and 2D angiographic images. *IEEE Transactions on Medical Imaging*, 35(9), 2107-2118.
11. Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V., Martinez-Gonzalez, P., and Garcia-Rodriguez, J. (2018). A survey on deep learning techniques for image and video semantic segmentation. *Applied Soft Computing*, 70, 41-65.
12. Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., and Yuille, A. L. (2017). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834-848.
13. LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
14. Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
15. Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., and LeCun, Y. (2014). *Overfeat: Integrated recognition, localization and detection using convolutional networks*. In 2nd International Conference on Learning Representations (ICLR), Banff, Canada.
16. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... and Rabinovich, A. (2015). *Going deeper with convolutions*. In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), Boston, MA, USA, 1-9.
17. He, K., Zhang, X., Ren, S., and Sun, J. (2016). *Deep residual learning for image recognition*. In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), Las Vegas, NV, USA, 770-778.
18. Simonyan K., Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-scale Image Recognition*. In Yoshua Bengio and Yann LeCun, editors, International Conference Learning Represent (ICLR), San Diego, CA, USA, 41-43.
19. Everingham, M., Eslami, S. A., Van Gool, L., Williams, C. K., Winn, J., and Zisserman, A. (2015). The pascal visual object classes challenge: A retrospective. *International Journal of Computer Vision (IJCV)*, 111, 98-136.
20. Zhou, B., Zhao, H., Puig, X., Fidler, S., Barriuso, A., and Torralba, A. (2017). *Scene parsing through ade20k dataset*. In Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR), Honolulu, HI, USA, 633-641.

21. Caesar, H., Uijlings, J., and Ferrari, V. (2018). *Coco-stuff: Thing and stuff classes in context*. In Proceedings of the IEEE conference on computer vision and pattern recognition, Salt Lake City, UT, USA, 1209-1218.
22. Long, J., Shelhamer, E., and Darrell, T. (2015). *Fully convolutional networks for semantic segmentation*. In Proceedings of the IEEE conference on computer vision and pattern recognition, Boston, MA, USA, 3431-3440.
23. Liu, W., Rabinovich, A., and Berg, A. C. (2015). Parsenet: Looking wider to see better. *arXiv preprint arXiv:1506.04579*.
24. Zhao, H., Shi, J., Qi, X., Wang, X., and Jia, J. (2017). *Pyramid Scene Parsing Network*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 2881-2890.
25. Chen, L. C., Papandreou, G., Schroff, F., and Adam, H. (2017). Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv:1706.05587*.
26. Noh, H., Hong, S., and Han, B. (2015). *Learning deconvolution network for semantic segmentation*. In Proceedings of the IEEE International Conference on Computer Vision (ICCV), Santiago, CL, 1520-1528.
27. Ronneberger, O., Fischer, P., and Brox, T. (2015). *U-net: Convolutional networks for biomedical image segmentation*. In Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, DE, 234-241.
28. Badrinarayanan, V., Kendall, A., and Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495.
29. Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H. (2018). *Encoder-decoder with atrous separable convolution for semantic image segmentation*. In Proceedings of the European conference on computer vision (ECCV), Munich, DE, 801-818.
30. Livne, M., Rieger, J., Aydin, O. U., Taha, A. A., Akay, E. M., Kossen, T., ... and Madai, V. I. (2019). A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Frontiers in neuroscience*, 13, 97.
31. Hilbert, A., Madai, V. I., Akay, E. M., Aydin, O. U., Behland, J., Sobesky, J., ... and Livne, M. (2020). BRAVE-NET: fully automated arterial brain vessel segmentation in patients with cerebrovascular disease. *Frontiers in artificial intelligence*, 78.

32. de Vos, V., Timmins, K. M., van der Schaaf, I. C., Ruigrok, Y., Velthuis, B. K., and Kuijf, H. J. (2021). Automatic cerebral vessel extraction in tof-mra using deep learning. *arXiv preprint arXiv:2101.09253*.
33. Dang, V. N., Galati, F., Cortese, R., Di Giacomo, G., Marconetto, V., Mathur, P., ... and Zuluaga, M. A. (2022). Vessel-CAPTCHA: an efficient learning framework for vessel annotation and segmentation. *Medical Image Analysis*, 75, 102263.
34. Shi, Z., Miao, C., Schoepf, U. J., Savage, R. H., Dargis, D. M., Pan, C., ... and Zhang, L. J. (2020). A clinically applicable deep-learning model for detecting intracranial aneurysm in computed tomography angiography images. *Nature communications*, 11(1), 6090.
35. Posa, A., Tanzilli, A., Barbieri, P., Steri, L., Arbia, F., Mazza, G., ... and Iezzi, R. (2022). Digital subtraction angiography (DSA) technical and diagnostic aspects in the study of lower limb arteries. *Radiation*, 2(4), 376-386.
36. Aydoğdu, A., Aydoğdu, Y., and Yakıncı, Z. D. (2017). Temel Radyolojik İnceleme Yöntemlerini Tanıma. *İnönü Üniversitesi Sağlık Hizmetleri Meslek Yüksek Okulu Dergisi*, 5(2), 44-53.
37. Sichtermann, T., Faron, A., Sijben, R., Teichert, N., Freiherr, J., and Wiesmann, M. (2019). Deep learning-based detection of intracranial aneurysms in 3D TOF-MRA. *American Journal of Neuroradiology*, 40(1), 25-32.
38. Saloner, D. (1995). The AAPM/RSNA physics tutorial for residents. An introduction to MR angiography. *Radiographics*, 15(2), 453-465.
39. Gonzalez, R. C. (2009). Digital image processing. Pearson education india.
40. Wevers, M., and Smits, T. (2020). The visual digital turn: Using neural networks to study historical images. *Digital Scholarship in the Humanities*, 35(1), 194-207.
41. İnternet: Sellner, J. (2017). Introduction to the Hessian feature detector. URL https://milania.de/blog/Introduction_to_the_Hessian_feature_detector_for_finding_blobs_in_an_image Son Erişim Tarihi: 24.05.2023
42. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
43. Raschka, S., and Mirjalili, V. (2019). Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2. Packt Publishing Ltd.

44. İnternet: Sevarac, Z. (2019). From Basic Machine Learning to Deep Learning in 5 Minutes. URL <https://www.deepnetts.com/blog/from-basic-machine-learning-to-deep-learning-in-5-minutes.html> Son Erişim Tarihi: 26.05.2023.
45. İnternet: S. Madeleine, (2021). "Detection and segmentation in medical imaging: types of deep learning models. URL <https://www.imaios.com/en/resources/blog/introduction-to-deep-learning-model-types-for-object-detection-in-medical-imaging> Son Erişim Tarihi: 26.05.2023
46. Dara, S., and Tumma, P. (2018). *Feature Extraction by Using Deep Learning: A Survey*. In 2018 Second international conference on electronics, communication and aerospace technology (ICECA), Coimbatore, IN, 1795-1801.
47. Keskenler, M. F., and Keskenler, E. F. (2017). Geçmişten günümüze yapay sinir ağları ve tarihçesi. *Takvim-i Vekayi*, 5(2), 8-18.
48. Kayaalp, K., and Süzen, A. A. (2018). Derin Öğrenme ve Türkiye'deki Uygulamaları, *İKSAD Yayınevi*, 25-28.
49. Minsky, M., and Papert, S. (1969). An introduction to computational geometry. *Cambridge tiass.*, HIT, 479(480), 104.
50. İnternet: Wikipedia. (2023). Neuron. URL <https://en.wikipedia.org/w/index.php?title=Neuron&oldid=1156721226> Son Erişim Tarihi: 24.05.2023.
51. İnternet: Kızrak, M. A. (2019). Şu Kara Kutuyu Açalım: Yapay Sinir Ağları. URL <https://ayyucekizrak.medium.com/%C5%9Fu-kara-kutuyu-a%C3%A7alim-yapay-sinir-a%C4%9Flar%C4%B1-7b65c6a5264a> Son Erişim Tarihi: 26.05.2023.
52. Pérez-Enciso, M., and Zingaretti, L. M. (2019). A guide for using deep learning for complex trait genomic prediction. *Genes (Basel)*, 10:553.
53. İnternet: Deshpande, A. (2017). A Beginners' Guide to Understanding Convolutional Neural Networks. URL <https://opendatascience.com/a-beginners-guide-to-understanding-convolutional-neural-networks/> Son Erişim Tarihi: 26.05.2023.
54. İnternet: Lienhard, D. A. (2017). David H. Hubel and Torsten N. Wiesel's Research on Optical Development in Kittens. URL <https://embryo.asu.edu/handle/10776/12995> Son Erişim Tarihi: 26.05.2023.
55. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... and Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377.

56. İnternet: Wikipedia. (2023). Convolution. URL <https://en.wikipedia.org/w/index.php?title=Convolution&oldid=1155936911> Son Erişim Tarihi: 24.05.2023.
57. Yani, M., Budhi Irawan, S. S. M., and Casi Setiningsih, S. M. (2019). *Application of Transfer Learning Using Convolutional Neural Network Method For Early Detection of Terry's nail*. In Journal of Physics: Conference Series, Ningbo, CN, 1201, 012052.
58. Hu, J., Shen, L., and Sun, G. (2018). *Squeeze-and-Excitation Networks*. In Proceedings of the IEEE conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, UT, USA, 7132-7141.
59. İnternet: Tomar, N. (2021). Squeeze and Excitation Networks. URL <https://idiotdeveloper.com/squeeze-and-excitation-networks/> Son Erişim Tarihi: 26.05.2023.
60. İnternet: Amidi, A. and Amidi, S. (2019). Recurrent Neural Networks Cheatsheet. URL <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks> Son Erişim Tarihi: 26.05.2023.
61. Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., and Muller, P. A. (2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33(4), 917-963.
62. Chung, J., Gulcehre, C., Cho, K., and Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv Preprint arXiv:1412.3555*
63. Bahdanau, D., Cho, K., and Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *arXiv Preprint arXiv:1409.0473*.
64. İnternet: Raschka, S. (2016). STAT 453: Introduction to Deep Learning and Generative Models. URL https://sebastianraschka.com/pdf/lecture-notes/stat453ss21/L19_seq2seq_rnn-transformers_slides.pdf Son Erişim Tarihi: 24.05.2023.
65. Luong, M. T., Pham, H., and Manning, C. D. (2015). Effective approaches to attention-based neural machine translation. In *The Association for Computational Linguistics*, 1412–1421.
66. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... and Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.

67. Lei Ba, J., Kiros, J. R., and Hinton, G. E. (2016). Layer normalization. *arXiv Preprint arXiv:1607.06450*.
68. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... and Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv Preprint arXiv:2010.11929*.
69. Zhang, Z., Liu, Q., and Wang, Y. (2018). Road extraction by deep residual u-net. *IEEE Geoscience and Remote Sensing Letters*, 15(5), 749-753.
70. Jha, D., Smedsrud, P. H., Riegler, M. A., Johansen, D., De Lange, T., Halvorsen, P., and Johansen, H. D. (2019). *Resunet++: An advanced architecture for medical image segmentation*. In 2019 IEEE international symposium on multimedia (ISM), San Diego, CA, USA, 225-2255.
71. Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., ... and Zhou, Y. (2021). Transunet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*.
72. Di Noto, T., Marie, G., Tourbier, S., Alemán-Gómez, Y., Esteban, O., Saliou, G., ... and Richiardi, J. (2023). Towards automated brain aneurysm detection in TOF-MRA: Open data, weak labels, and anatomical knowledge. *Neuroinformatics*, 21(1), 21-34.
73. İnternet: Noto, D. T. (2022). Lausanne TOF-MRA Aneurysm Cohort. URL <https://openneuro.org/datasets/ds003949/versions/1.0.1> Son Erişim Tarihi: 26.05.2023.
74. He, Y., Hu, T., and Zeng, D. (2019). Scan-flood fill (SCAFF): *An Efficient Automatic Precise Region Filling Algorithm for Complicated regions*. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops(CVPRW), Long Beach, CA, USA, 0-0.
75. İnternet: Micheau, A. and Hoa D. (2022). Anatomy of arteries of the brain and circle of Willis on a TOF MRA. URL <https://www.imaio.com/en/e-anatomy/brain/mra-brain> Son Erişim Tarihi: 26.05.2023.
76. Pieper, S., Halle, M., and Kikinis, R. (2004). *3D Slicer*. In 2004 2nd IEEE international symposium on biomedical imaging: nano to macro, 632-635.
77. Yushkevich, P. A., Gao, Y., and Gerig, G. (2016). ITK-SNAP: *An Interactive Tool for Semi-automatic Segmentation of Multi-modality Biomedical Images*. In 38th annual international conference of the IEEE engineering in medicine and biology society, Orlando, FLA, USA, 3342-3345.

78. Nyúl, L. G., and Udupa, J. K. (1999). On standardizing the MR image intensity scale. *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 42(6), 1072-1081.
79. Choi, D., Shallue, C. J., Nado, Z., Lee, J., Maddison, C. J., and Dahl, G. E. (2019). On empirical comparisons of optimizers for deep learning. *arXiv Preprint arXiv:1910.05446*.





Gazili olmak ayrıcalıktır