

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME MİMARİLERİ İLE MR TARAMALARINDAN OMURİLİĞİN
OTOMATİK BÖLÜTLENMESİ VE MS LEZYONLARININ AYIRICI TANISI**

DOKTORA TEZİ

RUKİYE POLATTİMUR

TEZ DANIŞMANI
DOÇ. DR. EMRE DANDIL

BİLECİK, 2024

10669850

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**DERİN ÖĞRENME MİMARİLERİ İLE MR TARAMALARINDAN OMURİLİĞİN
OTOMATİK BÖLÜTLENMESİ VE MS LEZYONLARININ AYIRICI TANISI**

DOKTORA TEZİ

RUKİYE POLATTİMUR

TEZ DANIŞMANI
DOÇ. DR. EMRE DANDIL

BİLECİK, 2024

10669850

BEYAN

“Derin Öğrenme Mimarileri ile MR Taramalarından Omuriliğin Otomatik Bölütlenmesi ve MS Lezyonlarının Ayırıcı Tanısı” adlı Doktora Tezinin hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR	X	DESTEK ALINMAMIŞTIR	
Destek alındı ise;			
Destekleyen kurum: Bilecik Şeyh Edebali Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü (BAP)			
Desteğin Türü		Proje Numarası	
BAP (Bilimsel Araştırma Projesi)		2021-01.BŞEÜ.03-02	
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:		T.C. Akdeniz Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu Karar Tarihi: 15.09.2021 Karar Sayısı: KAEK-644	

Rukiye POLATTİMUR

Tarih

.....

İmza

.....

ÖN SÖZ

Bu tez çalışmasında, konu seçimi sürecinden başlayarak tüm tez çalışmam boyunca, sürecimi titizlik ile takip ederek akademik gelişim sürecime maksimum katkıyı sunmayı çalışan, desteğini hiçbir zaman eksik etmeyen ve karşılaştığım her problemin çözümünde bilgi ve tecrübelerini cömertçe paylaşan değerli hocam Doç. Dr. Emre DANDIL'a; çalışmalarında karşılaştığım zorlukları aşmamda bana rehberlik eden ve her türlü sorumda değerli bilgi, teknik ve tecrübelerini esirgemeyen değerli hocam Dr. Öğr. Üyesi Mehmet Süleyman YILDIRIM'a teşekkür etmek isterim. Tez çalışmasına konu olan servikal omurilik MS lezyonlarının tespiti için veri temin edilmesine katkı sunan ve radyolojik bulguların değerlendirilmesi konusunda engin bilgi birikimi ile çalışmaya yön veren Akdeniz Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim Üyesi Prof. Dr. Abdullah Utku ŞENOL'a; tezimin bilimsel olarak ilerlemesine olan katkılarından dolayı değerli tez izleme jüri üyeleri Sayın Doç. Dr. Mustafa Zahid YILDIZ ve Doç. Dr. Çiğdem TURHAL'a sonsuz teşekkürlerimi sunuyorum. Tez çalışmasında kullanılan MR verilerini sağlayan ver verisetinin oluşmasına katkı sunan Akdeniz Üniversitesi Hastanesine ve yönetimine de teşekkürlerimi sunuyorum. Tez kapsamınca 2021-01.BŞEÜ.03-02 numaralı Proje Numarası ile destekleyen Bilecik Şeyh Edebali Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'ne teşekkürlerimi sunuyorum.

Bu süreçte her zaman yanımda olan ve bana inanan ailemin desteği sayesinde emin adımlarla daha güçlü ilerledi. Zorlu çalışma dönemlerimde gerek moral desteği, gerekse sabırları ile bana güç veren, her daim yanımda olduklarını hissettiren sevgili annelerim (Hava ÖZÜBEK, Ayşe POLATTİMUR), babalarım (Muhittin ÖZÜBEK, Metin POLATTİMUR) ve kardeşlerime minnettarım.

Akademik hayatımın her anında olduğu gibi doktora eğitimimin başından beri desteğini esirgemeyen emeği, desteği ve sevgisiyle yanımda olan çok değerli eşim Yasin Onur POLATTİMUR'a en içten teşekkürlerimi sunarım. Doktora süreciyle hayatımıza katılan ve bu süreç içerisinde gelişimlerine şahit olduğum, ilham kaynağım olan canım kızım İnci POLATTİMUR'a ve canım oğlum Cihangir POLATTİMUR'a bu tez çalışmasını armağan ediyorum.

Rukiye POLATTİMUR

2024

ÖZET

DERİN ÖĞRENME MİMARİLERİ İLE MR TARAMALARINDAN OMURİLİĞİN OTOMATİK BÖLÜTLENMESİ VE MS LEZYONLARININ AYIRICI TANISI

İnsan omuriliği, merkezi sinir sisteminin oldukça organize ve karmaşık bir parçasıdır ve işlevi nöral sinyallerin beyinden (duyusal bilgi) periferik sinir sistemine (motor bilgisi) ve periferik sinir sistemden beyne iletilmesini sağlamaktır. MS (Multipl Skleroz), omurilikte meydana geldiğinde beyin, omuriliğin ve optik sinirin beyaz ve gri maddesini etkiler. MS hastalığının erken teşhisi, hastalığın ilerlemesini yavaşlatmak ve semptomların kontrol altına alınmasını sağlamak açısından büyük önem taşır. Erken dönemde doğru tedaviye başlamak, hastalığın daha ağır ataklar yapmasını engelleyebilir ve hastanın yaşam kalitesini artırabilir. Bu sayede, MS'in ilerlemesini durdurmak ya da yavaşlatmak mümkün olabilir. MS hastalığının teşhisinde klinik semptom/bulgular, beyin omurilik sıvısı incelemeleri, uyarılmış potansiyeller ve Manyetik Rezonans Görüntüleme (MRG) bulguları kullanılmaktadır. Özellikle, MRG'nin kullanımının yaygınlaşması ve bilgisayar destekli sistemlerin gelişmesi, MS hastalığının tanısı ve takibinde önemli katkılar sağlamıştır. Diğer taraftan, başta derin öğrenme modelleri olmak üzere, yapay zeka algoritmaları ile MR görüntülerinden omuriliğin bölütlenmesi ve omurilik bölgesinde MS lezyonları bulunup bulunmadığına dayanan çalışmalar da son yıllarda oldukça öne çıkmıştır. Ancak yine de, bu ve benzeri çalışmalar belli oranda başarıya ulaşmış olsalar da, veriseti boyutunun küçüklüğünden kaynaklı veri miktarının azlığı ve MS lezyonlarının oldukça küçük bir hacme sahip olması gibi nedenlerden dolayı yapılan çalışmalarda MS tespiti başarılarının düşük olduğu görülmektedir.

Bu tez çalışmasında, derin öğrenme ile aksiyel ve sagittal gibi farklı düzlemlerden alınan T2-ağırlıklı MR görüntüleri üzerinde servikal omurilik kesit alanı (OKA), ve beyin omurilik sıvısı (BOS) alanlarının bölütlenmesi ve omurilikte oluşan MS lezyonlarının ayırıcı tanısı gerçekleştirilmiştir. Çalışma kapsamında, öncelikle, Akdeniz Üniversitesi Hastanesinden temin edilen servikal omurilik bölgesi MR verileri ile servikal omurilik bölgesi/kesit alanı (OKA), BOS alanı ve omurilik sınırları içerisinde bulunan MS lezyonlarının bölütleme işlemlerini gerçekleştirmek için bir veriseti hazırlanmıştır. Bu veriseti üzerinde, U-Net mimarisi tabanlı geliştirilen olan FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarileri kullanılarak, sagittal ve aksiyel düzlemlerdeki MR görüntülerinde, omurilik ve beyin omurilik sıvısı alanlarının bölütlenmesi sağlanarak, omurilik sınırları içerisinde bulunan MS lezyonları da tespit edilmiştir. Ayrıca önerilen mimarilerle elde edilen sonuçlar, Att U-Net (Attention U-Net),

Res U-Net (Residual U-Net) ve Att-Res U-Net (Attention Residual U-Net) olmak üzere karma mimariler ile de karşılaştırılmıştır.

Tez çalışmasında, ayrıca hazırlanan servikal omurilik verisetinde bölütlenmesi istenen alanların maskeleme işlemleri için omurilik aksiyel OKA/BOS, omurilik aksiyel MS ve omurilik sagittal MS veri alt grupları oluşturulmuştur. Hazırlanan servikal omurilik veriseti üzerinde omurilik alanının bölütlenmesi ve MS lezyonlarının tespit edilmesi için, model başarılarını ölçmek için piksel benzerliği temeline dayanan DSC (Dice Similarity Coefficient), PRE (Precision) ve REC (Recall) metrikleri kullanılırken, hacimsel bazlı olarak VOE (Volumetric Overlap Error) ile RVD (Relative Volume Difference) ve mesafe bazlı olarak ASD (Average Surface Distance) ile HD95 (95th percentile Hausdorff Distance) metrikleri kullanılmıştır. Verisetinde ilk olarak omurilik aksiyel OKA/BOS alt veri grubu ile deneysel çalışmalar gerçekleştirilmiştir. Yapılan model eğitimleri sonunda OKA bölütlenmesi için Con-FractalSpiNet mimarisi ile %94.99 DSC skoru, BOS bölgesi için FractalSpiNet mimarisi ile %93.00 DSC skoru ve tüm omurilik bölgenin bölütlenmesi için FractalSpiNet kullanılarak %96.54 DSC skoru ile en yüksek başarımlar elde edilmiştir. Diğer omurilik aksiyel MS veri alt grubu üzerinde gerçekleştirilen eğitimler sonucunda ilk bölütleme bölgesi olan OKA için en başarılı sonuçlar Con-FractalSpiNet ve FractalSpiNet mimarileri ile sırasıyla %98.89, %98.88 DSC skoru elde edilirken, MS lezyonlarının tespit edilmesinde en başarılı sonuçlar Con-FractalSpiNet ve FractalSpiNet mimarileri ile %91.48 ve %90.90 DSC skorları ile başarılmıştır. Yine aynı veri alt grubunda, MS'siz omurilik alanının bölütlenmesi için model eğitimleri sonucunda, en başarılı modeller Con-FractalSpiNet ve FractalSpiNet için sırasıyla %97.25 ve %97.17 DSC skorları elde edilmiştir. Omurilik sagittal MS veri alt grubu üzerinde yapılan deneysel sonuçlar incelendiğinde, omurilik alanı ve MS'siz omurilik alanlarının bölütlenmesi için gerçekleştirilen model eğitimleri sonucunda, Att-Res U-Net mimarisi ile sırasıyla %97.06 ve %95.16 DSC skorları elde edilirken, MS lezyonlarının tespit edilmesinde Con-FractalSpiNet kullanılarak %56.25 DSC skoru ile en başarılı sonuçlara ulaşılmıştır. Tüm sonuçlar değerlendirildiğinde, U-Net tabanlı önerilen FractalSpiNet mimarileri kullanılarak, servikal omurilik bölgesi ve bu bölgedeki MS lezyonlarının bölütlenmesinde, var olan çalışmalara göre oldukça rekabetçi sonuçlar edilmiştir.

Anahtar Kelimeler: Omurilik, Servikal Bölge, MR Görüntüleme, Bölütleme, Derin Öğrenme, U-Net, FractalSpiNet, MS Lezyon Tespiti.

ABSTRACT

AUTOMATIC SEGMENTATION OF THE SPINAL CORD FROM MR SCANS AND DIFFERENTIAL DIAGNOSIS OF MS LESIONS WITH DEEP LEARNING ARCHITECTURES

The human spinal cord is a highly organised and complex part of the central nervous system and its function is to transmit neural signals from the brain (sensory information) to the peripheral nervous system (motor information) and from the peripheral nervous system to the brain. When MS (Multiple Sclerosis) occurs in the spinal cord, it affects the white and grey matter of the brain, the spinal cord and the optic nerve. Early diagnosis of MS is important to slow the progression of the disease and control symptoms. Starting the right treatment early can prevent the disease from causing more severe attacks and improve the patient's quality of life. In this way, it may be possible to stop or slow the progression of MS. Clinical symptoms/signs, cerebrospinal fluid tests, evoked potentials and Magnetic Resonance Imaging (MRI) findings are used to diagnose MS. In particular, the widespread use of MRI and the development of computer-aided systems have contributed significantly to the diagnosis and follow-up of MS. On the other hand, studies based on the segmentation of the spinal cord from MR images using artificial intelligence algorithms, especially deep learning models, and the presence or absence of MS lesions in the spinal cord region have also become prominent in recent years. However, although these and similar studies have achieved a certain level of success, it can be seen that the success in MS detection in these studies is low due to reasons such as the small amount of data due to the small size of the dataset and the small volume of MS lesions.

In this thesis, the segmentation of cervical spinal cord cross-sectional area (CSA) and cerebrospinal fluid (CSF) areas on T2-weighted MR images taken from different planes such as axial and sagittal with deep learning and differential diagnosis of MS lesions in the spinal cord were performed. In the study, a dataset was first prepared to perform segmentation of cervical spinal cord CSA, CSF area and MS lesions within the spinal cord boundaries using cervical spinal cord MR data obtained from Akdeniz University Hospital. In this dataset, FractalSpiNet, Con-FractalSpiNet and Att-FractalSpiNet architectures, developed based on U-Net architecture, were used to segment the spinal cord and CSF areas in MR images in sagittal and axial planes, and to detect MS lesions within the spinal cord boundaries. In addition, the results obtained with the proposed architectures are also compared with mixed architectures, namely Att U-Net (Attention U-Net), Res U-Net (Residual U-Net) and Att-Res U-Net (Attention Residual U-Net).

In this thesis, spinal cord axial CSA/CSF, spinal cord axial MS and spinal cord sagittal MS data subgroups were created to mask the areas to be segmented in the cervical spinal cord dataset. For segmentation of the spinal cord area and detection of MS lesions on the prepared cervical spinal cord dataset, DSC (Dice Similarity Coefficient) based on pixel similarity was used to measure model success, PRE (Precision) and REC (Recall) metrics were used, VOE (Volumetric Overlap Error) and RVD (Relative Volume Difference) as volume-based metrics, and ASD (Average Surface Distance) and HD95 (95th percentile Hausdorff Distance) as distance-based metrics. Firstly, experimental studies were performed on the axial CSA/CSF sub-dataset of the spinal cord. At the end of the model training, the best results were obtained with 94.99% DSC score with Con-FractalSpiNet architecture for CSA segmentation, 93.00% DSC score with FractalSpiNet architecture for CSF region and 96.54% DSC score with FractalSpiNet for segmentation of the whole spinal cord region. As a result of the training performed on the other subset of MS spinal axial data, the best results for the first segmentation region, the CSA, were obtained with the Con-FractalSpiNet and FractalSpiNet architectures with DSC scores of 98.89% and 98.88% respectively, while the best results for MS lesion detection were obtained with the Con-FractalSpiNet and FractalSpiNet architectures with DSC scores of 91.48% and 90.90% respectively. In the same data subset, the most successful models for segmentation of the non-MS spinal cord area were Con-FractalSpiNet and FractalSpiNet with DSC scores of 97.25% and 97.17%, respectively. When analysing the experimental results on the sagittal spinal cord MS data subset, 97.06% and 95.16% DSC scores were obtained with the Att-Res U-Net architecture as a result of model training for segmentation of the spinal cord area and spinal cord areas without MS, while the most successful results were obtained with a DSC score of 56.25% using Con-FractalSpiNet for detection of MS lesions. When all the results are evaluated, using the proposed U-net based FractalSpiNet architectures, highly competitive results were obtained in the segmentation of the cervical spinal cord region and MS lesions in this region compared to existing studies.

Keywords: Spinal Cord, Cervical Region, MR Imaging, Segmentation, Deep Learning, U-Net, FractalSpiNet, MS Lesion Detection.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	x
KISALTMALAR VE SİMGELER LİSTESİ	xiii
1. GİRİŞ	1
1.1. Tezin Amacı ve Hedefleri.....	6
1.2. Araştırma Sorusu ve Hipotez	8
1.3. Tez Çalışmasının Katkısı	8
1.4. Tezin Organizasyonu.....	10
2. LİTERATÜR TARAMASI	12
2.1. Geleneksel Yaklaşımlar (Manuel, Yarı Otomatik ve Tam Otomatik)	13
2.2. Makine Öğrenmesi Yaklaşımları	17
2.3. Derin Öğrenme ve U-Net ile Yapılan Çalışmalar	18
3. OMURİLİK VE YAPISI	27
3.1. Omurilik MS Lezyonları.....	28
3.2. MS’de Epidemiyoloji.....	29
3.3. MS Etiyolojisi.....	31
3.4. MS Belirtileri, Tanı ve Teşhisi.....	31
3.5. Servikal Omurilik ve MS’in MR ile Görüntülenmesi	33
4. MATERYAL VE YÖNTEM.....	35
4.1. Verisetleri	36

4.1.1.	Global Veriseti (SCGMSC)	37
4.1.2.	Servikal Omurilik MR Veriseti	39
4.1.3.	Veri Etiketleme ve Ön-İşleme	42
4.2.	Veri Artırma	47
4.3.	Metodoloji	48
4.3.1.	Derin Öğrenme.....	48
4.3.2.	U-Net Mimarisi.....	51
4.4.	Hibrit U-Net Modelleri.....	54
4.4.1.	Attention (Dikkat) U-Net.....	54
4.4.2.	Residual U-Net	56
4.5.	Önerilen U-Net Tabanlı Derin Öğrenme Mimarileri.....	57
4.5.1.	FractalSpiNet.....	59
4.5.2.	Con-FractalSpiNet	63
4.5.3.	Att-FractalSpiNet.....	64
5.	DENEYSEL SONUÇLAR.....	66
5.1.	Optimize Edilen Hiper Parametreler	66
5.2.	Performans Metrikleri	69
5.3.	Yazılım ve Donanımsal Altyapı.....	71
5.4.	Omurilik Aksiyel OKA/BOS Alt Veri Kümesinde Elde Edilen Sonuçlar.....	73
5.5.	Omurilik Aksiyel MS Alt Veri Kümesinde Elde Edilen Sonuçlar	80
5.6.	Omurilik Sagittal MS Alt Veri Kümesi ile Elde Edilen Sonuçlar	87
6.	TARTIŞMA.....	96
7.	SONUÇ	105
	KAYNAKÇA	108

TABLÖLAR LİSTESİ

Sayfa

Tablo 2.1. Geleneksel ve derin öğrenme yöntemlerini içeren omurilik sınırları ve farklı omurilik lezyonlarının tespit edilmesini içeren literatür çalışmaları	25
Tablo 2.1.'in devamı.....	26
Tablo 3.1. Mcdonald Kriterleri 2017	33
Tablo 4.1. SCGMSC açık kaynak veriseti içerik bilgileri (K:Kadın, E:Erkek).....	38
Tablo 5.1. Tez çalışması kapsamında deneysel çalışmalarda kullanılan tüm verisetleri ve derin öğrenme mimarileri	66
Tablo 5.2. U-Net ve diğer tüm modeller için tercih edilen hiperparametre değerleri	67
Tablo 5.3. Çalışmada kullanılan bilgisayarın donanımsal yapısı ve teknik özellikleri	72
Tablo 5.4. Omurilik aksiyel OKA/BOS veri detayları	73
Tablo 5.5. Omurilik aksiyel OKA/BOS alt veri kümesi model parametre sayısının 200 epoch için model eğitim süresi, model doğruluk ve IoU sonuçları	74
Tablo 5.6. Omurilik Aksiyel OKA/BOS alt veri kümesinde FractalSpiNet mimarileri ve diğer U-Net mimarileri için OKA alanın bölütleme sonuçları	76
Tablo 5.7. Omurilik aksiyel OKA/BOS alt veri kümesinde FractalSpiNet mimarileri ve diğer U-Net mimarileri için BOS alanın bölütleme sonuçları	78
Tablo 5.8. Omurilik OKA/BOS aksiyel alt veri kümesinde FractalSpiNet mimarileri ve diğer tüm U-Net mimarileri için OKA ve BOS tüm alanın bölütleme sonuçları	79
Tablo 5.9. Omurilik aksiyel MS alt kümesinin detayları.....	80
Tablo 5.10. Omurilik aksiyel MS alt veri kümesinde model parametre sayısının 200 epok için model eğitim süresi, doğruluk ve IoU sonuçları	81
Tablo 5.11. Omurilik aksiyel MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için OKA alanı bölütleme sonuçları	83
Tablo 5.12. Omurilik aksiyel MS alt veri kümesinde FractalSpiNet mimarileri ve diğer U-Net mimarileri için elde edilen MS lezyonlarının bölütleme sonuçları	84
Tablo 5.13. Omurilik aksiyel MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için MS'siz omurilik alanının bölütleme sonuçları	86

Tablo 5.14. Omurilik sagital MS alt veri kümesini detayları	88
Tablo 5.15. Omurilik sagital MS alt veri kümesinde model parametre sayısının 200 epoch için model eğitim süresi, doğruluk ve IoU sonuçları	88
Tablo 5.16. Omurilik sagital MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için omurilik alanın bölütleme sonuçları	90
Tablo 5.17. Omurilik sagital MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için MS lezyonlarının bölütleme sonuçları.....	92
Tablo 5.18. Omurilik sagital MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için MS'siz omurilik alanın bölütleme sonuçları	94
Tablo 6.1. Omurilikte GM bölütlemesi için SCGMSC verisetinde FractalSpiNet mimarileri ve U-Net mimarilerinin sonuçlarının değerlendirilmesi	101
Tablo 6.2. FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet ile literatürde yapılmış benzer ölçekli çalışmalarının karşılaştırılması.....	103
Tablo 6.3. Tüm modellerin eğitimleri sonunda her bir test seti için toplam tespit süresi ve test verisetindeki tek bir görüntü için ortalama tespit süresi	104

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1. Sagital servikal omurilik MR verisi(a), aksiyel omurilik MR kesiti, MR maske ve etiketli veri(b), aksiyel omurilik MR kesiti, MR maske ve etiketli veri(c), sagital omurilik MR kesiti, MR maske ve etiketli veri (d)	5
Şekil 3.1. Omurilik vertebra anatomisi	27
Şekil 3.2. Omurilik aksiyel kesitte beyaz madde ve gri madde yapısı	28
Şekil 3.4. MS dünya geneli prevelansı haritası	30
Şekil 3.5. Servikal ve torasik omurilik bölgesi T1a, T2a sagital ve aksiyel MR verileri..	34
Şekil 4.2. Veri setlerinde bulunan MR görüntüsü, MR görüntüsüne ait işaretlenmiş maske görüntüleri ve ilgili alanın işaretlenmesi (a) omurilik GM/BM aksiyel T2a MR, (b) omurilik OKA/BOS aksiyel T2a MR, (c) omurilik MS aksiyel T2a MR, (d) omurilik MS sagital T2a MR	37
Şekil 4.3. SCGMSC verisetinde her bir veri sağlayıcısı için kullanılan MR verileri ve MR görüntüsüne ait maske verileri. (a, c) MR kesiti, (b, d) uzman tarafından etiketlenmiş maske.....	39
Şekil 4.6. Servikal omuriliğin sagital ve aksiyel kesit OKA/BOS T2a MR görüntüsü ve MR görüntüsünün maske verileri	43
Şekil 4.7. Servikal Omurilik MS Aksiyel T2a MR görüntüsü ve MR görüntüsünde MS lezyonun konumu	44
Şekil 4.8. Servikal Omurilik MS Aksiyel T2a MR verileri 128x128 olarak yeniden boyutlandırılmış örnek görseller.....	45
Şekil 4.9. Servikal Omurilik MS Sagital T2a MR görüntüsü ve MR görüntüsünün maskeleri.....	45
Şekil 4.10. Servikal Omurilik MS Sagital T2a MR verileri ve MR görüntüsüne ait işaretlenmiş maske verilerinin görüntüleri	46
Şekil 4.11. Servikal Omurilik MS Sagital T2a MR verileri 320x320 olarak yeniden boyutlandırılmış örnek görseller.....	47
Şekil 4.12. Evrişim sinir ağı model aşamaları.....	49
Şekil 4.14. U-Net mimarisinde dikkat (attention) blok yapısı	55

Şekil 4.15. U-Net mimarisinde artık (residual) blok yapısı	56
Şekil 4.16. Fractal evrişim blok yapısı	59
Şekil 4.17. U-Net evrişim blok yapısı(a), FractalSpiNet evrişim blok yapısı(b)	61
Şekil 4.18. Fraktal evrişim yapısı basit yapıdan genişleyen yapıya doğru a, b, c sırasıyla ilerlemektedir. FractalNet evrişim temel yapısı $fcz = \text{conv}(z)$ (a), 2^{c-1} evrişimiyle genişleyen fraktal yapı ikinci genişlemede b'de, üçüncü genişlemede c'deki gibi ilerlemektedir. c'de görüldüğü gibi her evrişim bloğu bir evrişim, batch normalizasyon ve ReLu aktivasyon fonksiyonu olarak tasarlanmıştır	62
Şekil 4.19. Tez çalışması kapsamında geliştirilen U-Net tabanlı FractalSpiNet mimarisinin açık hali	63
Şekil 4.20. Tez çalışması kapsamında geliştirilen U-Net tabanlı Con-FractalSpiNet mimarisinin açık hali	64
Şekil 4.21. Tez çalışması kapsamında geliştirilen U-Net tabanlı Att-FractalSpiNet mimarisinin açık hali	65
Şekil 5.1. Omurilik Aksiyel OKA/BOS verisi için U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet model eğitimleri sonucunda elde edilen (a) eğitim kaybı, (b) eğitim doğruluğu, (c) doğrulama kaybı ve (d) doğrulama doğruluğu değerlerinin grafikleri (200 epok, batch size=8)	75
Şekil 5.2. Tüm model eğitimleri sonunda omurilik aksiyel OKA/BOS test kümesinden bazı örnek görseller için OKA bölütleme sonuçları ve DSC skorları	77
Şekil 5.3. Tüm model eğitimleri sonunda omurilik aksiyel OKA/BOS test kümesinden bazı örnek görseller için BOS bölütleme sonuçları ve DSC skorları	78
Şekil 5.4. Tüm model eğitimleri sonucunda omurilik aksiyel OKA/BOS test kümesinden bazı örnek görseller için OKA ve BOS tüm alanın bölütlemel sonuçları ve DSC skorları	80
Şekil 5.5. Omurilik aksiyel MS alt veri kümesi için U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet model eğitimleri sonucunda elde edilen eğitim kaybı(a), eğitim doğruluğu(b), doğrulama kaybı(c) ve doğrulama doğruluğu(d) değerlerinin grafikleri (200 epok, batch size=8)	82
Şekil 5.6. Tüm mimariler için omurilik aksiyel MS test kümesinden bazı görseller için OKA alanının bölütleme sonuçları ve DSC skorları	83

Şekil 5.7. Tüm model eğitimleri sonunda omurilik Aksiyel MS test verisetinden bazı örnek görseller için MS lezyonlarının DSC tahmin skorları	85
Şekil 5.8. Tüm derin öğrenme mimarileri için omurilik aksiyel MS test kümesinde bazı örnek kesitler için MS'siz omurilik alanın bölütlenmesi ve DSC skorları.....	87
Şekil 5.9. Omurilik sagittal MS alt veri kümesi için U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet model eğitimleri sonucunda elde edilen eğitim kaybı (a), eğitim doğruluğu (b), doğrulama kaybı (c) ve doğrulama doğruluğu (d) değerleri grafikleri (200 epok)	89
Şekil 5.10. Tüm mimariler için omurilik sagittal MS test kümesindeki bazı örnek kesitler için tüm omurilik alanın bölütlenmesi ve başarılan DSC skorları	91
Şekil 5.11. Tüm mimariler için omurilik sagittal MS test kümesindeki bazı örnek görüntüler için MS lezyonlarının bölütleme sonuçları ve DSC skorları	93
Şekil 5.12. Tüm mimariler için omurilik sagittal MS test kümesindeki bazı örnek kesitler için MS'siz omurilik alanın bölütleme sonuçları ve DSC skorları.....	95
Şekil 6.1. Önerilen FractalSpiNet mimarileri ve modeller kullanılarak omurilik alanının bölütlenmesi (a), beyin omurilik sıvısı alanının bölütlenmesi (b), omurilik ve beyin omurilik sıvısı tüm alanın bölütlenmesi (c) için nispeten düşük başarıma sahip sonuçlar	97
Şekil 6.2. Önerilen FractalSpiNet mimarileri ve diğer tüm modeller için omurilik aksiyel MS alt veri kümesinde tüm omurilik alanının bölütlenmesi (a), omurilik MS lezyonlarının bölütlenmesi (b), MS lezyonları olmayan omurilik alanının bölütlenmesi (c) için daha düşük başarıma sahip kesitler	98
Şekil 6.3. Önerilen FractalSpiNet mimarileri ve diğer tüm modeller için sagittal düzlem alt veri kümesinde tüm omurilik alanının bölütlenmesinde (a), omurilik MS lezyonlarının bölütlenmesinde (b), MS lezyonları olmayan omurilik alanının bölütlenmesinde (c) daha düşük başarımlı sonuçlar	100
Şekil 6.4. Önerilen FractalSpiNet mimarileri ve diğer tüm modellerin SCGMSC verisetinde omurilik GM bölütleme sonuçları.....	101

KISALTMALAR VE SİMGELER LİSTESİ

ASD	: Ortalama Simetrik Yüzey Mesafesi (Average Symmetric Surface Distance)
BOS	: Beyin Omurilik Sıvısı
BT	: Bilgisayarlı Tomografi (Computed Tomography)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağları- ESA)
CNS	: Central Nervous System
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
COCO	: Bağlamdaki Ortak Nesneler (Common Objects in Context)
COLAB	: Google Colabratory
OKA	: Cross Section Area
BOS	: Cerebrospinal Fluid
ÇSS	: Çevresel/Periferik Sinir Sistemi
DSC	: Dice Benzerlik Katsayısı (Dice Similarity Coefficient)
DSÖ	: Dünya Sağlık Örgütü
FCL	: Tam Bağlantılı Katman (Fully Connected Layer)
FLAIR	: Sıvı ile Zayıflatılmış Ters Çevirme İyileştirmesi (Fluid Attenuated Inversion Recovery)
Fast R-CNN	: Hızlı Bölgesel Evrişimsel Sinir Ağları
Faster R-CNN	: Daha Hızlı Bölgesel Evrişimsel Sinir Ağları
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
GAN	: Çekişmeli Üretici Ağ (Generative Adversial Network)
GPU	: Grafik İşlem Birimi (Graphical Processing Unit)
GM	: Gri Madde (GM:Gray Matter)
JSC	: Jaccard Benzerlik Katsayısı (Jaccard Coefficient Similarity)
HD95	: Hausdorff Mesafesi (Hausdorff Distance 95)

k-NN	: k-En Yakın Komşuluk (k-Nearest Neighbours)
LDA	: Lineer Diskriminant Analizi
LR	: Öğrenme Oranı (Learning Rate)
MSS	: Merkezi Sinir Sistemi
MR	: Manyetik Rezonans
MRG	: Manyetik Rezonans Görüntüleme
MS	: Multiple Skleroz
NifTI	: Nörogörüntüleme Bilişim Teknolojisi Girişimi
OKA	: Omurilik Kesit Alanı
PRE	: Kesinlik (Precision)
R-CNN	: Bölge Tabanlı Evrişimsel Sinir Ağı (Region Based CNN)
ReLU	: Rektifiye Doğrusal Ünite
RoI	: Tahmini Önemli Bölge (Region of Interest)
REC	: Duyarlılık (Recall)
R-CNN	: Bölgesel Evrişimsel Sinir Ağları
ReLU	: Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear Unit)
RoI	: İlgi Bölgesi (Region of Interest)
RVD	: Göreceli Hacim Farkı (Relative Volume Difference)
SCGMC	: Spinal cord grey matter segmentation challenge
SVD	: Küçük Damar Hastalığı (Small Vessel Disease)
T	: Tesla
T1a	: T1a (T1*w, T1w)
T2a	: T2a (T2*w, T2w)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
TPR	: Doğru Pozitif Oranı (True Positive Rate)

TPU	: Tensor İşleme Birimi
USG	: Ultrason Görüntüleme
U-Net	: U-Şeklindeki Ağ Yapısı
VOE	: Alan Yoğunluk Farkı (Volumetric Overlap Error)



1. GİRİŞ

İnsanda sinir sistemi, vücudu etkileyen iç ve dış uyaranlardan bilgi elde eden ve elde edilen bilgiyi işleyen, vücut içerisinde hücreler ağı sayesinde sinyallerin ilgili organ ve sistemlere iletimini sağlayan, vücutta bu iletilere karşılık uyarılma, değerlendirme gibi görevleri etkili ve hızlı bir şekilde gerçekleştiren bütüncül bir sistemdir. İnsan sinir sistemi anatomik olarak bir bütün olarak değerlendirilirken, fizyolojik olarak ise merkezi sinir sistemi (MSS) ve çevresel (ÇSS) olmak üzere iki temel yapıdan oluşmaktadır. Merkezi sinir sistemi vücudun en önemli iki yapısı olan beyin ve omurilikten oluşurken, çevresel sinir sistemi ise vücudun geneline yayılmış olan sinir ağlarından oluşmaktadır(Mortazavi vd., 2012: 299).

İnsan omuriliği (medulla spinalis veya spinal kord), MSS'nin oldukça organize ve karmaşık bir parçasıdır ve nöral sinyallerin beyinden (duyusal bilgi) periferik sinir sistemine (motor bilgisi) ve periferik sinir sistemden beyne iletilmesini sağlamaktır (R Polattimur ve Dandil, 2023: 245). Bu bilgi, beyaz maddede (BM, white matter) bulunan miyelinli motor ve duyusal aksonlardan geçer ve çoğunlukla gri maddede (GM, grey matter) bulunan omurilik internöronlar tarafından iletilir ve kontrol edilir(De Leener vd., 2016: 125). Omurilik, omurga kanalının içinde güvenli bir şekilde yer almakta olup beyin omurilik sıvısı (BOS) ile çevrilidir. Bu sıvı, farklı yoğunluklara sahip olup omuriliği korur. Ayrıca omurilik, omur diskleri tarafından da çevrelenerek dış etkenlere karşı ek bir koruma altındadır (Stroman vd., 2014: 1070)

Omurilik, servikal, torasik ve lomber olmak üzere 3 ana bölümden oluşmaktadır. Omurilik kesit alanı (OKA) yetişkin bir bireyde servikal seviyede ortalama 67 ila 101 mm² arasında değişiklik göstermektedir(Y. Chen vd., 2020: 857). Omurilik sahip olduğu kıvrımlı yapı nedeniyle oldukça zorlu bir çalışma alanı olmasına rağmen gelişen MR teknolojisi sayesinde nokta atışı klinik tanı ile cerrahi işlemler yapılabilir(Karkucak ve Köksal, 2021: 147). Çünkü vertebral cisim, intervertebral disk, omurilik kanalı ve omurilik dahil olmak üzere servikal omurganın anatomik ayrıntılarını açıkça gösterebilmekte olup omurilik alanı MR görüntüleme ile 3 farklı planlardan sagittal, aksiyel ve koronal açıdan/düzlemden çekim sağlayabilmektedir(Zhuo vd., 2022: e210292). Diğer taraftan sağladığı niceliksel bilgilere ek olarak multipl skleroz (MS), travmatik ve nörodejeneratif hastalıklar gibi bir dizi nörolojik bozuklukta omurilik hasarını değerlendirmek için son yirmi yılda giderek daha fazla kullanılmaktadır(Gros vd., 2018: 215). Bu sayede kord boyunca değişken hacme ve şekle sahip olan omurilik alanı uçtan uca incelenebilmektedir. Özellikle MS lezyonlarının

MR verileri ile teşhis edilebilmesi %80 ile %92 oranında başarıma ulaşmaktadır(Bot vd., 2002: 46). MS lezyonları tüm omurilik boyunca gözlemlenebilmekle birlikte, sıklıkla servikal omurilikte (%56,4) gözlemlenmektedir. Bu nedenle klinik çalışmalarda MS vakalarında, MR taramaları genellikle boyun (servikal) bölgesine odaklanarak yapılmaktadır(M. Chen vd., 2013: 1051), (Bot vd., 2004: 226),(Patek ve Stewart, 2023: 406). MS vakalarının değerlendirme aşamasında McDonald kriterleri çok önemli bir yer tutmaktadır ve bu kriterler ile MS tanısı koymak için klinik takipte MR'ın önemine özellikle vurgu yapılmaktadır(Thompson vd., 2018: 162). Geçmişten günümüze çok hızlı gelişim gösteren MR teknolojisi sayesinde nokta atışı klinik tanı ile cerrahi işlemler yapılabilmektedir(Karkucak ve Köksal, 2021: 147). MR teknolojisi önemli avantajları olmasına rağmen omuriliğin görüntülenecek bölgesindeki yapısal farklılıklar, bölgesel zorluklar veya hastalığa bağlı sorunlar, görüntü kalitesini olumsuz etkileyebilir. Bu da, istenen seviyede net görüntüler elde edilmesini zorlaştırabilir(Stroman vd., 2014: 1070),(De Leener vd., 2016: 125).

Omurilik MR görüntüleme, omurilik ve omuriliğin etrafını saran sinirler, diskler ve omur kemiklerinin ayrıntılı bir şekilde incelenmesi amacıyla kullanılan bir tıbbi görüntüleme yöntemidir(Kearney vd., 2015: 327). Omurilik bölgesinde oluşan disk hernisi (fitik), omurilik tümörleri, omurilik yaralanmaları, enfeksiyonları veya iltihaplanmaları ve özellikle MS gibi nörolojik hastalıkların tanısında oldukça yardımcı olmaktadır. MR görüntüleri, MS'in neden olduğu plak adı verilen hasarlı bölgeleri (lezyonlar) ortaya çıkarabilmektedir. Omurilik MR görüntüleme, MS lezyonlarının omurilikte olup olmadığını ve hastalığın omurilik üzerindeki etkisini değerlendirmek için kullanılır. Bu, MS tanısını doğrulamak ve hastalığın seyrini izlemek için gereklidir(Wattjes vd., 2015: 157).

MS, kronik, iltihaplanma, demiyelinizasyon ve nörodejenerasyon gibi çeşitli semptomlarla karakterize edilen merkezi sinir sisteminin bir hastalığıdır(Grigoriadis ve Van Pesch, 2015: 3),(Mortazavi vd., 2012: 299). Bu hastalık MSS içindeki sinir liflerini çevreleyen ve izole eden yağ maddesi miyeline zarar vererek iltihaplanmaya neden olur (Mortazavi vd., 2012: 299). Bu materyal sinir sinyallerinin bir nörondan diğerine hızlı bir şekilde iletilmesinden sorumludur(Dilokthornsakul vd., 2016: 1014). MS hastalığının temel nedeni, beyin ve omurilikteki beyaz ve gri madde bölgelerinde demiyelinizan plakların birikmesi ile oluşmaktadır. Bu plaklar, sinir hücrelerinin etrafındaki miyelin tabakasına zarar vererek sinir sinyallerinin iletimini engeller ve hastalığın belirtilerine yol açmaktadır. Demiyelinizasyon (demiyelinizasyon; sinir hücrelerinin etrafını çevreleyen

miyelin kılıflarının hasar görmesi) veya miyelin kaybı sinir sistemi boyunca sinyallerin olması gerektiği şekilde doğru bir iletişim kuramamasına neden olmaktadır. Doğru sinyallerin ulaşmadığı bölgelerde vücut fonksiyonlarının bozularak bulanık görme, ağır kas güçsüzlüğü ve duyuşal değışiklikler şeklinde semptomların gözlemlenmesine neden olmaktadır.

MS lezyonlarının etiyolojisi tam olarak bilinmemekle birlikte, otoimmünite, genetik yatkınlık ve çevresel faktörlerin tamamının hastalığı tetikleyen unsurlar olduğu bilinmektedir(Weinshenker, 1996: 291),(Sawcer vd., 1996: 464). Dünya sağık örgütünün (DSÖ) verilerine göre dünyada 1,8 milyondan fazla kişinin MS hastası olduğunu ve tüm yaş aralıklarında gözlemlenmekle beraber genç erişkinlerde ve özellikle kadınlarda daha sık gözlemlendiğini belirtmişlerdir (World Health Organization (WHO), 2015)),(Nouri vd., 2015: E675).

MS, hastasının yaşamını fiziksel, ekonomik, psikolojik ve sosyal yönleriyle etkileyebilen, sıklıkla özörlölölölge yol açabilen kronik bir hastalıktır(Yıldırım ve Fadıloğlu, 2014: 100). Çeşitli semptomların varlığı ve öngörölölölme doğası nedeniyle hastalar gelecekleriyle ilgili belirsizlikle yaşamak zorunda kalmakla beraber, MS ilerleyen evrelerde nörolojik morbidite ve mortaliteye sebep olabilmektedir(Lemay vd., 2021: 102766). Özellikle nörodejeneratif hastalıkların erken evredeki tanısı zordur (Herholz vd., 2002: 302) ve merkezi sinir sisteminin yöneticisi olan beyinde meydana gelen hastalıklar tüm vücudumuzdaki organları etkileyebilmektedir. MS, ilk olarak 1868 yılında Jean-Martin Charcot tarafından yeni bir sinir sistemi hastalığı olarak bildirilmiştir (Zalc, 2018: 3482) ve ardından Schumacher (1965), Poser (1983) ve McDonald (2001) MS için klinik tanı kriterleri yayınlamışlardır. McDonald Kriterlerinde (Thompson vd., 2018: 162) MS hastalığı için bir dizi değeriendirme ölçütü sunulmuştur. Bu ölçütler zaman içerisinde revize edilerek günümüzde de en sık kullanılan yöntemlerden biri haline gelmiştir(Toğrol ve Demir, 2013: 15).


Hastalık farklı seviyelere göre ifade edilmekte olup bazı seviyelerinde dönemsel ataklarla kendini gösterirken bir kısmında ise hastalığın başında veya son döneminde hızla ilerleyici bir süreç yaşanabilmektedir(M. Öztürk ve Tek, 2019: 10). Bu nedenle MS plaklarının sinir sisteminin farklı yerlerinde, farklı zamanlarda oluştuğunun gözlemlenmesi ile birlikte McDonald Kriterleri'nin vurguladığı önemli konulardan biri; MS tanısı koyarken klinik takip için MRG (Manyetik Rezonans Görüntölölme)'in önemine özellikle vurgu yapılmaktadır(Thompson vd., 2018: 162). MR omurilik

görüntülemeleri, MS hastalarının %80-92'sinde doğru teşhis konulmasını sağlamaktadır ve bu yöntem, MS tanısında oldukça etkili bir araçtır(Bot vd., 2002: 46).

Son yıllarda bölütleme teknikleri manuel (el yordamı), yarı otomatik ve tam otomatik makine öğrenmesi metotları kullanılarak oldukça hızlı bir gelişim kazanmıştır. Görüntüleme teknikleri ile bölütleme metotlarının eş zamanlı olarak gelişim göstermesi biyomedikal mühendisliği gibi birçok türevlerinin çoğalmasını sağlamıştır. Özellikle MRG gibi görüntü sağlayıcı cihazların kaliteli veriler üretmeye başlaması bölütleme çalışmalarına hız kazandıran en önemli etkenlerin başında gelmektedir. Fakat 1980'lerde önerilen evrimsel sinir ağları (convolutional neural networks, CNN) yüksek matematiksel kapasite gerektiren işlemler olması nedeniyle o dönemde mevcut bilgisayar donanımı yeterli olmadığı için kısıtlı bir kullanımının olmasına sebep olmuştur. Bu nedenle sırasıyla grafik işlem birimi (graphical processing unit, GPU) ve tensor işlem birimi (Tensor İşleme Birimi, TPU) bilgisayar işlem birimlerinin kullanılmaya başlanması ile çok çeşitli evrim mimarileri tasarlanmaya ve kullanılmaya başlanarak otomatik bölütleme metotların kullanımında artış sağlanmıştır. Bu gelişmelere paralel olarak derin öğrenme mimarileri ile yapılan bölütleme çalışmalarından çok başarılı sonuçlar alınması bu alanda literatüre kazandırılan çalışmaların sayısını oldukça hızlandırmıştır.

Omurilik bölütlemesi için önerilen çalışmalar incelendiğinde MR görüntülemenin yaygın olarak tercih edildiği görülmektedir(Wattjes vd., 2015: 157). Omurilik bölgesi aksiyel, sagittal ve koronal açıdan taranmış MR verisetleri kullanılarak tüm omurilik veya bölgesel olarak servikal, torasik ve lomber birimleri ayrı ayrı incelenebilmektedir. Omurilik kesit alanı (OKA/CSA), beyin omurilik sıvısı (BOS/CSF), GM ve BM gibi alanları zaman içerisinde farklı derin öğrenme yaklaşımlarıyla bölütleme çalışmaları yapılmıştır. Omurilik yapısının incelenmesine ek olarak bu alan içerisinde bulunan lezyon, tümör vb. gibi hasarlı doku oluşumların yerlerinin tespit edilmesi ile ilgili olarak yapılan çalışmalar bu alanda oldukça zorlu çalışma konuları olarak değerlendirilmektedir. Şekil 1.1'de gösterildiği gibi Şekil 1.1(a) ile ifade edilen servikal omurilik sagittal MR görüntüsünden, enine kesitler alındığında Şekil 1.1(b) ve Şekil 1.1 (c)'de görüldüğü gibi aksiyel MR verileri elde edilmektedir. Aksiyel MR verilerinde OKA ve BOS alanlarının maske görüntüsü ve etiket işlemi yapılmış görüntüsü verilmiştir. Diğer aksiyel veri olan Şekil 1.1(c) ile OKA ve omurilik MS lezyonlarının MR verisi, maske MR verisi ve etiket işlemi yapılmış görüntüsü verilmiştir. Sagittal MR verisi Şekil 1.1(d) ise yine OKA ve maske MR verisi ile etiket işlemi yapılmış görüntüsü verilmektedir.

Daha önceki çalışmalarda omurilik bölütlemesi için birçok yöntem önerilmesine rağmen paylaşıma açık veri havuzu oldukça kısıtlıdır. Yapılan çalışmalar ile paylaşılmış popüler verisetleri mevcuttur fakat spesifik olarak çalışma yapılmak istenilen organ, doku, tümör vb. alanlar için özel verisetleri hazırlamak hala zorunlu bir gerekliliktir. Diğer taraftan ise veri elde edilmesi oldukça zahmetli bir iş yükü olabilmektedir. Bunun nedeni olarak ise hasta gizliliği ile ilgili olarak yasal düzenlemelerinin yetersizliği sebebiyle yaşanabilecek etik sorunlar başta olmak üzere, personel eksiklikleri vb. durumların etkili olduğu söylenebilmektedir. Derin öğrenme ile yapılan çalışmalarda veri miktarı ile model başarımlarını etkileyen önemli bir parametre iken biyomedikal çalışma alanlarında yüksek veri sayılarına ulaşmak her çalışma için mümkün olmamaktadır. Derin öğrenme alanında yapılan çalışmalar sonucunda bu kısıtı ortadan kaldıran bir bölütleme yöntemi olan U-Net mimarisi 2015 yılında, Olaf Ronneberger, Phillip Fischer, ve Thomas Brox tarafından “U-Net: Convolutional Networks for Biomedical Image Segmentation” makalesinde duyurulmuştur(Ronneberger vd., 2015: 234).



Şekil 1.1. Sagittal servikal omurilik MR verisi(a), aksiyel omurilik MR kesiti, MR maske ve etiketli veri(b), aksiyel omurilik MR kesiti, MR maske ve etiketli veri(c), sagittal omurilik MR kesiti, MR maske ve etiketli veri (d)

U-Net mimarisi, ESA temelli bir yapı olarak, CNN için yüksek veri gereksinimine ihtiyaç var iken, U-Net sayesinde oldukça az bir veri seti ile başarılı sonuçlar elde etmenin mümkün olduğunu yapılan çalışmalar ile kanıtlamıştır. Evrişim ağlarına yapılan bu katkı sayesinde, U-Net mimarisinin U şeklindeki kolay yapılandırılabilen yapısı kullanılarak, birçok farklı derin ağ ile yeni hibrid modeller geliştirilmiştir. Ayrıca, modele

katkı saęlayan eřitli yaklařımlar sayesinde yeni modeller oluřturulmuř ve bu modeller literatüre kazandırılmıřtır.

Bu tez alıřmasında klinik karar vericilerine ve uygulayıcılarına yardımcı olacak rutin prosedürlerine ek bir derin öğrenme temelli farklı bir disiplinel yaklařım olan otomatik bölütleme yöntemi önerilmektedir. alıřmada, servikal omurilik bölgesi T2-aęırlıklı (T2a) MR verileri ile ok kapsamlı veri setleri hazırlanmıřtır. Servikal omurilik bölgesi T2a MR verileri sagittal ve aksiyel MR ekimlerini içermektedir. Bu sayede ilk olarak omurilik OKA/BOS aksiyel T2a MR verileri ile omurilik kesit alanı (OKA) ve beyin omurilik sıvısı alanı (BOS), ikinci olarak omurilik MS aksiyel T2a MR verileri ile aksiyel kesit omurilik ve MS lezyonlarını, üçüncü olarak omurilik MS sagittal T2a MR sagittal kesit omurilik ve MS lezyonlarını tespit etmek için MR kesitleri kullanılmıřtır. MR görüntüleri ve bu görüntüler için tespit edilmesi hedeflenen alanlar için uzman etiketleme işlemleri yapılarak üç farklı veriseti grubu hazırlanmıřtır. Tezde ayrıca, bu verisetlerine ek olarak açık kaynak olarak paylaşılan bir veri seti olan SCGMC (Spinal cord grey matter segmentation challenge) veri seti ile omurilik gri madde ve beyaz madde alanlarının tespit edilmesi saęlanmıřtır. Hazırlanan verisetleri üzerinde, U-Net mimarisi tabanlı geliştirilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarileri ile model eğitimleri tamamlanarak elde edilen tüm sonuçlar deęerlendirilmiřtir. Dięer taraftan, elde edilen sonuçlar, U-Net mimarisinden türetilmiř hibrit modeller Att U-Net, Res U-Net ve Att-Res U-Net mimarilerinin sonuçları ile de karřılařtırılmıřtır. bu modeller için elde edilen sonuçlar literatürde sıklıkla kullanılan hacimsel, mesafe bazlı ve karışıklık matrisi temelli benzerlik metrikleri ile kapsamlı bir řekilde deęerlendirilmiřtir.

1.1. Tezin Amacı ve Hedefleri

Omurilikte MS lezyonları ile ilgili olarak hekimlerin verdięi bilgiler ışığında omurilik ve omurilik MS lezyonlarının sınırlarının ve konumlarının tespit edilmesi klinik olarak oldukça zahmetli olmakla birlikte son nihai karar verme esnasında ekiřmeli fikirler olabildięinden bahsedilmiřtir. Bu bağlamda omurilikte MS lezyonlarının tespit edilmesinin oldukça zorlu bir klinik konu olduęu ortak görüşmeler sonucunda anlařılmıřtır. Sorunun bütüncül açıdan ele alınması klinik karar vericiler için ve MS hastalarının süreçlerini takip edilebilmesi açısından oldukça önemli olmaktadır. ünkü MS’li hastaların açısından deęerlendirildięinde, kiřilerin günlük yaşamlarını kısıtlayacak kadar etkili olabilen bu lezyonlar hastalığın ilerleme aşamalarında bakım alma ihtiyacı ortaya ıkabilmekte ve daha ileri seviye lezyonlar ölümle bile sonuçlanabilmektedir. Bu nedenle hastalığın ne aşamada olduęu, lezyonlarının konumlarının ve büyüklüklerinin

tespit edilmesi hayati önem taşımaktadır. Tüm bu durumlar incelendiğinde hastalığın tanı ve tedavi aşamasında hekimlere yardımcı olacak karar destek sistemlerinin klinik prosedürlere entegre edilmesi karar vericilerin iş yükünü azaltarak daha doğru kararlar verebilmelerine katkı sunacaktır. Diğer taraftan, MS lezyonlarının konumları itibariyle cerrahi operasyonlar oldukça zorlu olabilmektedir. Cerrahi travmayı, komplikasyon insidansını azaltmak ve cerrahi işlemde en yüksek sonuçlar elde edebilmek için MS lezyonlarının konumunun bilinmesi oldukça önemli olmaktadır. Bu tez çalışmasının amacı, klinik karar vericilerine ve uygulayıcılarına yardımcı olmak için servikal omurilik bölgesinin ve bu bölgedeki MS lezyonlarının otomatik tespiti ve bölütlemesini derin öğrenme tabanlı mimariler kullanarak sağlamaktır. Tez çalışmasının hedefleri ise şunlardır:

Hedef 1: Hazırlanan veriseti ile servikal omurilik bölgesinin ve beyin omurilik sıvısı alanlarının otomatik bölütlenmesi:

Bu hedefi gerçekleştirmek için Akdeniz Üniversitesi'nden Etik Kurul Onayı ile başvuru yapılarak verilerin temin edilmesi sağlanmıştır. Veriler retrospektif olarak temin edilmiş olup uzman eşliğinde gerçek maske işlemleri gerçekleştirilmiştir.

Hedef 2: Omurilikte MS lezyonları bulunan hastalardan alınan MR görüntüleri ile omurilik bölgesinin otomatik bölütlenmesi ve MS lezyonlarının tespit edilmesi:

Bu hedefi gerçekleştirmek için Akdeniz Üniversitesi'nden Etik Kurul Onayı başvuru yapılarak verilerin temin edilmesi sağlanmıştır. Veriler retrospektif olarak son yıllardaki MS teşhisi almış hastalardan elde edilmiş MR verilerini içermektedir. Aksiyel ve sagittal MR verileri için uzman eşliğinde gerçek maske işlemleri gerçekleştirilmiştir. Bölütleme işlemlerini gerçekleştirmek için derin öğrenme mimarisi modellerinden olan U-Net mimarisi tabanlı yeni modeller geliştirilmiştir.

Hedef 3: Omurilik alanı, beyin omurilik sıvısı ve MS lezyonlarının bölütlenmesi için derin öğrenme modellerinin kıyaslanması, güçlü ve zayıf yönlerinin belirlenmesi:

Bu hedefi gerçekleştirmek için literatürde sıklıkla kullanılan rekabetçi U-Net mimarileri kullanılarak omurilik alanı, beyin omurilik sıvısı alanı ve MS lezyonlarının tespit edilmesi sağlanmıştır. Bölütleme çalışmaları için temel U-Net mimarisi, Attention U-Net mimarisi, Residual U-Net mimarisi ve Attention Residual U-Net mimarileri ile model eğitimleri gerçekleştirilmiştir. Bu sayede yeni katman yapısına sahip U-Net mimarileri tasarlanması için çok yönlü sonuçlar elde edilmiştir.

Hedef 4: Omurilik alanı, beyin omurilik sıvısı ve MS lezyonlarının bölütlenmesi için yeni bir derin öğrenme mimarisi geliştirilmesi:

Tez çalışması kapsamında hazırladığımız özgün verisetlerini rekabetçi U-Net modelleri kullanılarak gerçekleştirilen bir dizi eğitimler ile bölütleme çalışmaları yapılmıştır. Tüm bu rekabetçi mimarilere ek olarak fractal evrişim yapısının U-Net modeline entere edilmesi ile yeni katman yapısına sahip olan FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet modelleri geliştirilmiştir. Tasarlanan yeni modeller ve özgün verisetleri ile omurilik bölgesi, beyin omurilik sıvısı alanları ve MS lezyonlarının bölütlenmesi işlemlerinin gerçekleştirilmiştir.

1.2. Araştırma Sorusu ve Hipotez

Literatürde omurilik MS lezyonlarının tespiti için yapılmış mevcut çalışmaların sınırlı olduğu ve veri seti kısıtı nedeniyle genelleştirilebilir olmadığı yapılan çalışmalarının karşılaştırılabilirliğinin az olmasına neden olmaktadır. Bununla beraber, güncel derin öğrenme modelleri ile kapsamlı çalışmaların sınırlı olması da yapılacak katkıyı sınırlandırmaktadır. Diğer taraftan, derin öğrenme modelleri ile elde edilen sonuçların oldukça yüksek başarıma sahip olması nedeniyle omurilik alanlarının bölütlenmesi ve MS lezyonlarının tespit edilmesi ile ilgili yapılacak çalışmalarda da yüksek başarılar elde edileceği öngörüsü değerlendirilmiştir. Ayrıca, omurilik bölgesinde MS lezyonlarının konumu ve boyutlarının oldukça küçük olması sebebiyle, önerilecek bir yaklaşımın klinik ortamlarda hekimlerin kullanabileceği karar destek sistemine entegre edilmesi hasta takip ve tedavi süreçlerini kolaylaştıracağı da açıktır.

Tez çalışmasının hipotezi: Hazırlanacak özgün bir veriseti ile önerilecek yeni bir derin öğrenme modeli kullanılarak aksiyel ve sagittal düzlemde servikal omurilik bölgesinin yüksek doğrulukla bölütlenmesi sağlanabilir ve bu bölgedeki MS lezyonları yüksek başarımla tespit edilebilir.

Tez çalışmasının araştırma sorusu: Servikal omurilik MR verilerinde gelişmiş derin öğrenme mimarileri kullanılarak yüksek başarı oranları ile omurilik alanın otomatik bölütlenmesi ve omurilik MS lezyonlarının tespit edilmesi gerçekleştirilebilir mi?

1.3. Tez Çalışmasının Katkısı

Bu tez çalışmasında, MR görüntüleri kullanılarak servikal omurilik alanının bölütlenmesi ve omurilik MS lezyonlarının tespiti için derin öğrenme modelleri kullanılması önerilmiştir. Önerilen yaklaşım, hekimlerin veya karar vericilerin kullandıkları manuel yaklaşımlara ek olarak otomatik olarak bölütleme işlemleri

gerçekleştirebilecekleri yenilikçi yöntemler içermektedir. Çalışmada, omurilik bölgesi ve bu bölgede bulunan MS lezyonlarının tespit edilmesi için U-Net (Ronneberger vd., 2015: 234) derin öğrenme mimarisi tabanlı yeni mimarileri önerilmiş (FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet modelleri) ve karma U-Net mimarileri olan Att U-Net, Res U-Net, Att-Res U-Net ile de sonuçlar karşılaştırılmıştır.

Omurilik bölütlenmesi ve omurilik MS lezyonlarının tespit edilmesi için önerilen bu tez çalışmasının katkıları aşağıdaki gibi listelenebilir:

- Servikal omurilik bölütlenmesi ve servikal omurilik MS lezyonlarının tespit edilmesi için hazırlanan veriseti ve yenilikçi mimariler ile bütüncül bir yaklaşım sunulmuştur.
- Servikal omurilik MR görüntüleri ile oluşturulan verisetinde birbirinden farklı alt gruplar oluşturularak veri setlerinin hazırlanması işlemleri tamamlanmıştır. İlk olarak aksiyel MR verileri ile omurilik OKA/BOS maskesi oluşturulmuştur. Aksiyel omurilik MR görüntülerinde, omurilik ve MS lezyonlarını tespit edebilmek için bir MS maskesi oluşturulmuştur. Benzer şekilde, servikal omurilik MR görüntülerinde de sagittal kesitler kullanılarak lezyonların belirlenmesi amacıyla bir MS maskesi hazırlanmıştır. Servikal omurilik MR görüntüleri ile üç farklı alt grup maske verileri oluşturularak omurilik, beyin omurilik sıvısı ve MS lezyonlarının tespit edilmesi için oluşturulmuştur. Yapılan deneysel çalışmalar sonucunda, elde edilen çıktılarından üretilen SCI-Expanded indeksli makale ile servikal omurilik MS aksiyel veriseti açık kaynak olarak paylaşımına sunulmuştur.
- Servikal omurilik bölütleme ve MS lezyonlarının tespit edilmesi için U-Net mimarisi temel alınarak FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarisleri geliştirilmiştir.
- FractalSpiNet, servikal omurilik bölgesinde önemli bir yenilik sunarak, farklı klinik senaryolara uyarlanabilen güvenilir ve etkili bir çözüm olarak öne çıkmaktadır.
- Önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarilerini kullanarak servikal omurilik tamamen otomatik bölütleme şekilde bölütlenmiştir.

- Önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarilerini ile servikal omurilik bölgesindeki MS lezyonlarının başarılı bir şekilde tespit edilmesi sağlanmıştır.
- Önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarilerinin ve diğer tüm mimarilerin eğitimleri sonunda performanslarının değerlendirilmesi için literatürde sıklıkla kullanılan temel metrikler ile model başarımları skorları çıkarılarak tüm mimarilerin başarı kıyaslaması yapılmıştır.

1.4. Tezin Organizasyonu

Bu tez, toplam 7 bölümden oluşmaktadır. Özetle bahsedecek olursak:

Bölüm 1’de, omurilik ve MS hastalığı hakkında bilgi verilmiş ve klinik süreçlere MR görüntülemenin katkısı, omurilik bölgesinde MS lezyonlarının tanı ve tedavi aşamasında kullanılan MR görüntüleme teknikleri hakkında temel bilgiler ortaya konulmuştur. Ayrıca, omurilik bölütleme ve MS lezyonlarının tespiti için kullanılacak yöntemler hakkında temel bilgisi verilmiştir. Tezin hipotezine, amacına ve organizasyonuna yönelik olarak önceki akademik çalışmalar hakkında bilgiler verilmiş ve tez çalışmasının fikri temelleri sunulmuştur.

Bölüm 2’de, omurilik bölütleme ve MS lezyonlarının tespit edilmesi çalışmaları üzerine derinlemesine literatür taraması yapılarak konu uçtan uca incelenmiştir. Bu alanda çalışılmış içerik sayısı oldukça kısıtlı olduğu için çerçeve geniş perspektiften bakılarak, makine öğrenmesi, derin öğrenme ve farklı U-Net mimarileri ile omurilik bölütleme konusunda yapılmış birçok çalışma değerlendirilmiş, çalışmaların detayları, sonuçları ve sınırlılıkları ayrı ayrı incelenmiştir.

Bölüm 3’te, omuriliğin görevleri ve MS hastalığının tanımı, epidemiyolojisi, etiyolojisi, hastalığın belirtileri, tanı ve teşhis süreçleri hakkında detaylar verilmiştir. Ayrıca, MS hastalığının teşhis ve sınıflandırılmasında kullanılan kriterler ve MS lezyonlarının incelenmesi için yararlanılan MR görüntüleme teknikleri hakkında bilgi verilmiştir.

Bölüm 4’te, tez çalışması süresince oluşturulan verisetleri tüm teknik detayları ile anlatılmıştır. Ayrıca, deneysel çalışmalar yürütülen diğer global veri seti hakkında teknik bilgi paylaşımı da yapılmıştır. Veri hazırlık aşamaları ve kullandığımız metodolojinin aşamaları hakkında detaylı bilgiler verilmiştir. Ek olarak bu bölümde, derin öğrenme,

evriřim mimari yapıları ve U-Net hakkında detaylar verilerek geliştirilen yeni modellerin tüm teknik detayları paylaşılmıştır.

Bölüm 5’te, tez çalışması kapsamınca hazırlanan özgün verisetleri ve global veriseti olmak üzere dört farklı veriseti kullanılarak U-Net, karma U-Net ve geliştirilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet modelleri olmak üzere toplam yedi mimari ile deneysel işlemler gerçekleştirilmiştir. Literatürde sıklıkla kullanılan ölçüm metrikleri ile model başarıları tablolar halinde kapsamlı bir şekilde verilmiştir. Ayrıca modellerden elde edilen verilerin sonuçları görsellerle açıklanmıştır.

Bölüm 6’da ise deneysel sonuçlardan elde edilen tüm çıktılar detaylı olarak değerlendirilmiştir ve literatürde yapılmış başarılı çalışmalar ile kıyaslayarak bu tez çalışmasının literatüre olan katkısı anlatılmıştır. Çalışmanın bilime katkıları ve kısıtları diğer çalışmalar ile kıyaslanmıştır ve önerilen yöntemin medikal görüntü işleme alanında kullanılabilirliği tüm yönleri ile ele alınmıştır.

Bölüm 7’de, deneysel çalışmaların literatürdeki çalışmalar ile kıyaslanmasının ardından, tez çalışmasının çıktıları değerlendirilerek literatüre olan katkısı anlatılmıştır. Bu nedenle, daha başarılı sonuçlar elde edebilmek amacıyla, veriseti iyileştirmelerine odaklanılmış ve metodolojinin güçlü ve zayıf yönleri vurgulanarak detaylı bir dizi öneri sunulurak tez bu şekilde sonlandırılmıştır.

2. LİTERATÜR TARAMASI

Servikal omurilik bölgesi bölütlenmesi ve omurilikte bulunan MS lezyonlarının tespit edilmesi ile ilgili olarak geçmişten günümüze kadar yapılmış birçok bilimsel çalışma bulunmaktadır. Omurilik alanının ve MS lezyonlarının bölütlenmesi çalışmaları kapsamında literatür incelendiğinde, genel anlamda en önemli konuların kullanılan veriseti ve bölütleme tekniklerinde tercih edilen metodolojik yaklaşım olduğu ve çalışmaların bu doğrultuda birbirinden farklılaştığı görülmektedir. Diğer taraftan, omurilik bölütlemesi ve bu sınırlar içerisinde lezyon, tümör gibi dokusal bozuklukların tespit edilmesi için önerilen yaklaşımlar, çalışmaların başarılarını direkt etkileyen en önemli etkindir. Bu nedenle, omurilik ve bu bölgede bulunan MS lezyonlarının tespit edilmesi için geçmişten günümüze kadar el yordamı (manuel), yarı otomatik ve tam otomatik gibi farklı yöntemler kullanılarak çalışmalar gerçekleştirilmiştir. Konunun zorlu bir çalışma süreci gerektirmesi ve farklı disiplinler yapıları içerisinde bulunduruyor olması sebebiyle, literatürde yapılmış çalışma sayısı oldukça kısıtlıdır. Bu kısıtın en büyük sebebi olarak ortak kullanıma sunulan detaylı bir veriseti olmaması ve bireysel çalışma bazlı hazırlanan verisetlerinin hazırlık aşamasının oldukça zahmetli olması gösterilebilir. Özgün veriseti oluşturma, etik onay sürecinin uzun olması, hastane çalışma ortamlarının oldukça yoğun olması ve personel eksikleri gibi engellere takılırken, hazırlanan verisetleri de etik kaygılar gerekçesi ile araştırmacıların kullanımı için çoğunlukla paylaşılmamaktadır. Günümüzde bu konunun farklı disiplinlerin ortak çalışmasını içermesi ve literatürde bu tarz çalışmaların hız kazanması multidisipliner çalışmaların ana motivasyon kaynağı olmaktadır. Nitekim gelişen görüntüleme teknikleri sayesinde yüksek kalitede görüntüler çok daha kısa MR çekim süresi sonucunda elde edilebilir olması iş yükünü ve bekleme süresini azaltarak yapılacak olan çalışmalara hız kazandırmıştır. Görüntü bölütlemesi çalışmalarında makine öğrenmesi ile başlayan bu süreç evrişim sinir ağları ve derin öğrenme modellerinin çok yoğun olarak literatüre kazandırılması araştırmacılar arasında ilgi duyulan bir çalışma alanı olmuştur. Özellikle CPU, GPU, TPU gibi merkezi işlem birimlerinin zaman içerisinde iyileştirilmesi sayesinde bilgisayarlar yüksek hesaplama kapasitesine ulaşarak yeni ve kapsamlı çalışmaların üretilmesine olumlu katkı sunmuştur. Sonuç olarak tıbbi görüntüleme ve biyomedikal görüntüleme alanındaki çalışmaların sayısında oldukça artış meydana gelmiştir.

MS lezyonlarının teşhisinde geleneksel klinik zorlukların aşılması için yenilikçi yaklaşımlardan sıklıkla yararlanılmaktadır. Bu bağlamda, MR görüntüleri kullanılarak

ilgilenilen lezyon alanların tespit edilmesi ve otomatik segmente edilmesi çalışmalarına yoğun bir ilgi gösterilmiş ve son yıllarda literatüre çok fazla katkı sunulmuştur. Geçmişten günümüze omurilik bölütlemesi ve lezyonlarının tespit edilmesi için aksiyel, koronal ve sagittal olmak üzere farklı MR planelleri ve T1, T2 gibi farklı çekim modalite özelliklerine sahip verisetleri hazırlanmıştır. Farklı çekim teknik özelliklere sahip MR görüntüleri ile manuel veya zamanla otomatize olan modeller ile farklı yaklaşımlar geliştirilmiştir. Omurilik çalışmalarında sıklıkla BM ve GM, OKA, BOS alanlarının bölütlenmesi çalışmaları yapılırken omurilik lezyonlarının veya tümörlerinin tespit edilmesi ile ilgili de kısıtlı olmasına rağmen yapılmış çalışmalar mevcuttur. Verisetlerinin yanı sıra çeşitli bölütleme teknikleri ile çalışmaların özgünlüğü arttırılmıştır. Manuel(Mirafzal vd., 2020: 406), yarı-otomatik(Losseff vd., 1996: 701), (El Mendili vd., 2015: 454), (Fonov vd., 2014: 817) ve tam otomatik(Koh vd., 2010: 3117), (Koh vd., 2011: 1467), (M. Chen vd., 2013: 1051), (Pezold vd., 2015: 107), (Gros vd., 2018: 215) teknikler var olmasına rağmen, günümüzde daha başarılı sonuçlar elde eden ve otomatik tekniklerden olan derin öğrenme metotları kullanılarak(Y. Zhang vd., 2019: 974), (McCoy vd., 2019: 737), (Gros vd., 2019: 901), (Reza vd., 2019: 487), (Merali vd., 2021: 10473) zaman maliyet açısından çok daha avantajlı mimariler ortaya konulabilmektedir. Derin öğrenme de özneteliklerin belirlenmesi işlemlerini otomatize edecek bir mimari yapının varlığı makine öğrenmesinde özneteliklerin manuel belirleme problemine çözüm olmuştur.

Literatür geçmişten bugüne manuel, yarı otomatik, tam otomatik bölütleme teknikleri olarak ilerlerken geleneksel görüntü işleme algoritmaları ve farklı makine öğrenmesi metotları kullanılarak yapılan çalışmalar literatür araştırması kapsamında değerlendirilmiştir.

2.1. Geleneksel Yaklaşımlar (Manuel, Yarı Otomatik ve Tam Otomatik)

Omurilik bölgesi bölütlenmesi ve MS lezyonlarının tespit edilmesi için geleneksel yaklaşımlar, genellikle klinik çalışmalar şeklinde yapılmış olmakla beraber, görüntü bölütlemesi kapsamında önerilmiş başlangıç ölçeğinde olan çalışmaları içermektedir. Görüntü bölütleme çalışmaları genel anlamda birçok alanda tıptan, mimarlığa, harita ve kadastrodan uzay bilimine kadar oldukça geniş kapsamda bilgi birikimine sahip olsada özel datasetler isteyen çalışmalar için hala yeni ve çalışılması heyecan veren konuların başında gelmektedir. Bu bağlamda omurilik bölgesi ve omurilik sınırları içerisinde tümör, lezyon ve diğer doku bozukluklarının bölütlenmesi için yapılmış çalışmalar sınırlı kalmaktadır. Klinik çalışmalar çerçevesinde ve bu süreçte gelişen yaklaşımlar ile

omurilik ve omurilik MS lezyonları ile ilgili olarak yapılan çalışmalar bulunmaktadır. Bu kapsamda; El Mendili ve arkadaşlarının (El Mendili vd., 2015: 454) önerdiği bir çalışmada omurilik OKA ve BOS bölgesinin manuel ve yarı otomatik yöntemle kıyaslanması üzerine bir çalışma yapılmıştır. 49'u sağlıklı denek olmak üzere, 29 amiotrofik lateral sklerozlu, 19 spinal müsküler atrofi, 14 omurilik yaralanmalı hasta grubu olmak üzere toplam 111 hasta verisi incelenmiştir. T2a 3B turbo spin eko görüntülerini kullanarak, OKA ve BOS bölgelerini manuel ve yarı otomatik yöntemlerle bölütlenmesi için C2-T9 omurilik bölgesi MR verileri kullanılmıştır. Elde ettikleri bulgular ışığında yarı otomatik bölütleme yöntemi ile omurilik alanının ölçümünde yüksek tekrarlanabilirlik ve doğruluk elde edildiğini ifade etmişlerdir. Yine El Mendili ve arkadaşlarının (Mendili vd., 2015: 1) yaptığı diğer bir çalışmada ise omuriliğin 3B T2a turbo spin eko MR taramalarından hem kesitsel hem de hacimsel ölçümleri mümkün kılan yarı otomatik çift eşik tabanlı (DTbM, Double threshold-based method) segmentasyon yöntemini kullanmışlardır. 82 sağlıklı denek olmak üzere 10 amiotrofik lateral sklerozlu, 10 spinal müsküler atrofi ve 10 omurilik yaralanmalı hastanın verileri kullanılarak çalışma yapılmıştır. Toplamda 59 sağlıklı hastanın MR görüntülerinden servikal omurilik şablonu standartı oluşturmak için, iyi ortalanmış düz omurilik görüntüleri kullanılarak doğru olasılıklı doku haritasına yol açan bir standardizasyon hattı tasarlanmıştır. Bölütlemelerin doğruluğu bir radyolog tarafından puanlanmıştır. Kord bölgesi kullanılarak DTbM, aktif yüzey yöntemi (ASM, active surface method), eşik bazlı yöntem (TbM, threshold-based method) ve manuel taslak oluşturma (temel gerçek) ile karşılaştırılmıştır. Önerilen sınırlı manuel müdahaleye sahip yarı otomatik bir bölütleme yöntemi olan DTbM, diğer yöntemlerden ASM ve manuel taslak ile kıyaslandığında daha iyi sonuç elde edilirken TbM yöntemi ile kıyaslandığında benzer ölçüde başarılı sonuçlar verdiği belirtilmiştir.

Losseff ve arkadaşları tarafından (Losseff vd., 1996: 701), MS tanısı almış 60 hasta için sakral kord alanı ve engellilik arasında bağlantının varlığı araştırılmıştır. Atrofinin ölçülmesi ve değerlendirmesi için yüksek dereceli yeniden üretilebilirliğini artırmak ve hastanın seri olarak izlenmesi gereken durumlar için yeni bir yöntem geliştirilmiştir. Bu bağlamda, Kurtzke'nin Genişletilmiş Sakatlık Durumu Ölçeği (EDSS, Expanded Disability Status Scale) ile ölçülen sakral kord alanı ve engellilik arasında güçlü bir korelasyon bulunması sakral kord alanı ve engellilik durumu arasında güçlü bir neden-sonuç ilişkisi olduğu sonucuna varmışlardır. Yapılan deneysel çalışmalar sonucunda atrofi ile kullanılan ölçek arasında kararlı bir korelasyon tespit edilmiş olup nörolojik bozulmanın hassas bir ölçüsü olduğu kanıtlanarak klinik ortamda tedavi protokollerine

dahil edilebileceği önerilmiştir. MS ile atrofi arasındaki bağlantının daha net anlaşılabilmesi için daha çok araştırma yapılmasının gerektiği sonucuna ulaşılmıştır.

Tench ve arkadaşları (Tench vd., 2005: 197) 10 sağlıklı hastadan elde ettikleri MR verilerini kullanarak servikal omurilik sınırlarının doğru bir şekilde ölçülebilmesi için kenar algılama (edge dedection) ve kısmi hacim ortalaması (PVA, partial volume averaging) yöntemlerini önermektedir. PVA, ölçüm hatalarının azaltılması ile daha doğru sonuca ulaşmak için kullanılan yarı otomatik bölütleme yöntemidir. Bu yöntemin, omurilik atrofisi çalışmalarında yararlı olabileceği sonucuna varılmıştır.

Horsfield ve arkadaşları (Horsfield vd., 2010: 446) 20 normal seyreden, 20 tekrarlayan-düzelen (RR, relapsing remitting), 20 ikincil ilerleyen (SP, sekonder progresif) MS tanısı olan toplam 60 hastadan elde edilen MR verileri kullanılarak yarı otomatik bölütleme yöntemi olan aktif yüzey modeli ile omurilik kesit alanının belirlenmesi ve klinik sakatlık skorlarının arasında nasıl ilişkili olduğunu bulmaya çalışmışlardır. Elde ettikleri sonuçlara göre mevcut bölütleme yöntemlerine göre daha iyi performans gösterdiği ve omurilik kesit alanı ile klinik sakatlık skorları arasındaki korelasyonlar, yöntemin omurilik atrofisini ölçmede yararlı olacağı sonucuna varmışlardır.

Koh ve arkadaşları (Koh vd., 2010: 3117) 52 hastadan elde edilen T2a MR verileri kullanılarak omuriliği ve dural keseyi otomatik olarak bölütlemek için tasarlanmış bilgisayar destekli bir teşhis sistemini önermektedirler. Bu sistem potansiyel bölgeleri tespit etmek için bir gradyan vektör akışı (GVF, Gradient Vector Flow) alanı kullanarak nihai bölütleme gerçekleştirmek için bağlı bileşen analizini kullanmaktadır. Manuel bölütlemeler ile kıyaslandığında yüksek doğruluk elde edilmiş ve bu yöntemin manuel bölütleme zorluklarına bir çözüm olabileceği ve klinik teşhis tutarlılığını artırarak lomber patolojilerin teşhisinin daha kolay olabileceği sonucu vurgulanmaktadır.

Kawahara ve arkadaşları (Kawahara vd., 2013: 848) özellikle MS'li hasta grubu ve sağlıklı deneklerden 3B T1 ve T2a omurilik MR görüntülerinden oluşan veri kümelerini kullanarak omurilik şekillerini belirleyebilmek için temel bileşen analizi (PCA, principal component analysis) yönteminden yararlanmaktadırlar. Oluşturulan veri kümesi ile bölütleme işlemlerinde manuel müdahaleyi en aza indirerek ve bölütleme görevlerindeki hassasiyeti artırarak omurilikle ilgili hastalıkların teşhisi ve izlenmesi için daha iyi araçlar sağlamayı amaçlamaktadır. Ayrıca önerilen bölütleme yönteminin doğruluğunu ve verimliliğini test etmek için bir bütüncül bir yaklaşım sunmaktadırlar.

Law ve arkadaşları (Law vd., 2013: 49) omurilik hattının çıkarılması ve omurilik bölütleme için gradyan rekabeti anizotropisi yöntemini önermektedirler. T1 ve T2a omurilik MR verileri kullanılarak omurilik bölgesinin yüksek doğruluk ve etkinlikte çalışma çıktılarının elde edilmesi, manuel ihtiyacı azaltarak tanı ve tedavi kolaylığı sağlayacağı düşünülmektedir.

Omurilik lokasyonunun tam otomatik olarak tespit edilmesi ile ilgili olarak önerilen bir çalışmada Gros ve arkadaşları (Gros vd., 2018: 215) omurilik merkez noktasının olasılıksal lokalizasyon haritası ile omurilik merkez çizgisinin genel uzaysal tutarlılığı arasında denge kurmaya çalışan OptiC algoritması kullanılmaktadır. Daha tutarlı sınırlar elde etmek için ise omurilik merkez hattının beyin bölgesi sınırlarından ayırmayı hedefleyen bir işlem eklenmiştir. 20 farklı merkezden nörolojik hastalıkları olan 173 hasta dahil 501 kişiden T1, T2, T2a MR verileri kullanılmıştır. OptiC'nin, Hough dönüşümüne dayanan son teknoloji ürünü omurilik lokalizasyon tekniğiyle karşılaştırıldığında özellikle ortalama kare hatası (averaged mean square error) olan patolojik vakalarda başarılı sonuçlar elde ettiği ifade edilmiştir.

Chen ve arkadaşları (M. Chen vd., 2013: 1051) deforme edilebilir atlas yöntemi ve topoloji kısıtlamaları kullanarak omurilik ve beyin omurilik sıvısı alanlarının bölütlemesine yardımcı olan bir yöntem önermektedirler. Çalışmada farklı hasta gruplarından T1, T2 MR verileri elde edilerek veri seti oluşturulmuştur. Omurilik bölütleme multipl skleroz gibi nörolojik hastalıkların analizinde, hastalığın ilerlemesi ile omurilik atrofi ve şekil değişiklikleriyle ilgili ölçümler arasında korelasyon olduğunu göstermek için farklı iki veri kümesi üzerinde değerlendirilmiştir. Sonuçlar manuel bölütlemelerle karşılaştırıldığında bu yöntem, omurilik MR görüntülerinde otomatik ve doğru bölütleme sağlayarak klinik karar verme sürecini desteklemekte ve manuel bölütleme gereksinimini azalttığı tespit edilmiştir.

Asman ve arkadaşları (Asman vd., 2014: 460) farklı hasta gruplarından ve T1, T2a MR görüntüleri kullanılarak omurilik GM ve BM alanlarının otomatik olarak segmente edebilmek için çoklu atlas yaklaşımlarını önermektedirler. Bu yöntem, omurilik gri ve beyaz madde bölgelerini otomatik olarak ayırmak için geliştirilmiştir ve özellikle MR görüntülerinde düşük kontrast ve gürültü oranları gibi zorlukları aşmak için tasarlanmıştır. Bu sayede, manuel bölütleme göre daha yüksek doğruluk sunmakta olup zaman açısından daha verimli olduğu tespit edilmiştir. Yöntem, multipl skleroz gibi nörolojik hastalıkların analizinde kullanılmakta ve omurilik atrofi gibi durumların değerlendirilmesine yardımcı olmaktadır.

De Leener ve arkadaşları (De Leener vd., 2015: 1705) omurilik gri bölgenin segmente edilmesi için farklı bireylerden elde edilen T2a MR görüntüleri kullanılarak bir veri seti hazırlanmıştır. Bu veri setini kullanarak gri ve beyaz maddeyi otomatik olarak bölümlere ayırmak için atlas deformasyon temeline dayanan yeni MNI-Poly-AMU şablonu ve probabilistik gri madde MR verilerine kaydedilerek omurilik atlasının standart maskesi oluşturulmuştur. Yöntem, manuel bölütleme karşılaştırıldığında yüksek doğruluk göstermektedir. Otomatik bölütleme, özellikle gri madde bölütlemesinde, manuel yöntemlere kıyasla daha tutarlı sonuçlar verdiği ve multipl skleroz ve diğer nörolojik hastalıkların analizinde kullanılabileceği, omurilik atrofisi gibi durumların değerlendirilmesine yardımcı olabileceği ve çeşitli multi-parametrik MR verilerinin metriklerinin doğru bir şekilde ölçülmesini sağlayabileceği belirtilmiştir.

Taso ve arkadaşları (Taso vd., 2015: 20) sağlıklı genç ve yetişkin deneklerden temin edilen T2a MR görüntüleri kullanılarak oluşturdukları veri seti ile omurilik beyaz ve gri bölgelerin bölütleme çalışması ve yaşla birlikte meydana gelen morfolojik değişikliklerin tensor tabanlı morfometri (TBM, Tensor-based morphometry) ile haritalanması için kullanılmasını amaçlamışlardır. Oluşturulan AMU40 şablonuna doğrusal olmayan uzamsal normalizasyonu ile bölütleme işlemi gerçekleştirilerek yaşlı grupta anlamlı anterior gri bölgenin atrofisini belirlenmesini sağladılar. Bu TBM'nin omurilikteki yerel yapısal değişiklikleri incelemede kullanılabilirliğini ilk kez gösteren bir çalışma olması bakımından önemli olmakla beraber, yaşa bağlı omurilik morfolojisi değişikliklerini araştırma potansiyelini vurgulamaktadır.

2.2. Makine Öğrenmesi Yaklaşımları

Manuel, yarı otomatik ve tam otomatik yöntemleri ile omurilik bölütleme çalışmaları süreç içerisinde yerini makine öğrenmesine bırakmaktadır. Çalışmalarda omurilik bölgesinin farklı planelerden taranmış MR verisetleri kullanılarak omurilik alanı, beyin omurilik sıvısı alanı, gri madde ve beyaz madde ve özellikle omurilik sınırları içerisinde bulunan MS lezyonları ve diğer tümör gruplarının bölütlenmesi için farklı yaklaşımlarla bölütleme yöntemleri önerilmiştir. Şimdiye kadar omuriliğin bölütlenmesi için manuel destekli(Mirafzal vd., 2020: 406), yarı-otomatik(Coulon vd., 2002: 1176), (Horsfield vd., 2010: 446), (Van Uiter vd., 2005: 224) ve tam otomatik(De Leener vd., 2015: 1705), (De Leener vd., 2014: 528) olmak üzere birçok çalışma önerilmiştir. Tam otomatik yöntemlerde makine öğrenmesi ve derin öğrenme tabanlı yaklaşımların yaygın olarak kullanılmıştır. Bu çalışmaların birinde, Chen ve arkadaşları (M. Chen vd., 2013: 1051) hem aksiyel hem de sagittal MR verileri kullanarak anatomi

odaklı omurilik ve beyin omurilik sıvısı bölgelerinin bölütlenmesini sağlamışlardır. Çalışmada, iki farklı veriseti ile yöntemin doğruluğu değerlendirilmiş ve manuel yöntemlere göre daha avantajlı olan yöntemin başarılı olduğu vurgulanmıştır. Bir diğer çalışmada, Yiannakas ve arkadaşları (Yiannakas vd., 2016: 71) geriye dönük MR verilerinden oluşan bir veriseti kullanarak servikal omurilik bölgesinin otomatik bölütlenmesini ve MS lezyonlarının tespit edilmesini sağlamışlardır. Çalışmada elde edilen sonuçlar başka yöntemler ile de kıyaslanarak çalışmanın başarısı değerlendirilmiştir.

Jois ve arkadaşları (Jois vd., 2018: 524) ise özel bir veriseti kullanarak omurilik bölgesinin dairesel aktif disklerini otomatik bölütlemek için bölge büyüme algoritmasını kullanmışlardır. Mirafzal ve arkadaşları (Mirafzal vd., 2020: 406) ise aksiyel ve sagittal açıdan taranmış 3B MR verilerini kullanarak omurilikte MS lezyonlarının tespitini gerçekleştirmişlerdir. Çalışmada, manuel olarak omurilik lezyonu tespiti yapan uzmanlara oranla önerilen yöntemin daha başarılı olduğunu göstermişlerdir. Bir başka çalışmada, Bédard ve arkadaşları (Bédard ve Cohen-Adad, 2022: 1031253) omurilik bölgesinin otomatik normalizasyonunu ve ölçümünü merkezi sinir sisteminin pontomedullary junction kullanarak gerçekleştirmişlerdir.

Sabaghian ve arkadaşları (Sabaghian vd., 2020: 811) makine öğrenmesi kümeleme algoritması yöntemlerinden biri olan K-Means kullanarak omurilik görüntülenmesi doğruluğunu arttırmayı amaçlamışlardır. T2a MR görüntülerinden oluşan veri seti kullanarak MR verisinde elde ettikleri benzer yoğunluk değerlerinin gruplanmasını sağlayarak omurilik ve omur yapısının bölütlenmesi gerçekleştirmişlerdir. Yoğunlukların kümelenmesi temeline dayalı bu sistem ile omuriliğin çevre doku yoğunluklarından ve yapılarından ayırmadaki zorluklara karşı güçlü bir yöntem olarak ifade edilmekte ve klinik aşamalarında kullanılmak için doğru bir bölütleme işlemi sunmakta olduğundan bahsedilmektedir. Manuel işlem süreçlerinde yaşanabilecek hataların aza indirgeyerek yüksek doğruluk ve tekrarlanabilirlik sağlayacağı belirtilmektedir.

2.3. Derin Öğrenme ve U-Net ile Yapılan Çalışmalar

Son yıllarda oldukça hızla gelişim gösteren derin öğrenme modelleri tıbbi görüntüleme alanında karar destek sistemi olarak sıklıkla kullanılmaktadır. Omuriliğin bölütlenmesi ve tespiti için derin öğrenme tabanlı birçok yöntem bulunmaktadır.

Gros ve diğerleri (Gros vd., 2019: 901) ilk olarak omurilik merkez hattının tespit edilmesi olmak üzere omurilik kordunun ve MS lezyonun otomatik bölütlenmesi için iki

aşamalı bir CNN modeli önermişlerdir. Tüm süreç 2 aşamaya bölünerek modelin aşırı öğrenmesinin önüne geçilmiştir. İlk model olan 2B dilate ESA ile omurilik merkez hattını tüm görüntüden çıkararak çalışma alanını küçültülmekte ve ikinci model olan 3B ESA ile omurilik bölgesi bölütlenerek lezyonların tespit edilmesi sağlanmaktadır. Bu sayede iki aşamalı süreç ile MRG hacminin tamamına kıyasla lezyon voxellerinin küçük oranını ele alarak bölütleme doğruluğunu artırmayı hedeflemektedirler. Çalışmada, 30 farklı merkezden toplanan sağlıklı, MS hastaları ve diğer omurilik patolojilerine sahip bireyler olmak üzere toplam 1042 kişiden elde edilen MR verileri kullanılmıştır. Veriler T1, T2a gibi farklı MR görüntüleme teknikleri kullanılarak hazırlanmıştır. Omurilik bölütleme sonuçları mevcut çalışmalardan çok iyi sonuç vermesine karşılık lezyon sonuçları manuel bölütleme sonuçlarına yakın kalmıştır.

Bu çalışmalardan birisinde, Horváth ve diğerleri (Horváth vd., 2019: 3) AMIRA (Averaged Magnetization Inversion Recovery Acquisitions) ismini verdikleri görüntü protokolünü kullanarak MD-GRU (Multi-Dimensional Gated Recurrent Units) adı verilen yeni bir tekrarlayan evrişim ağı (RNN, recurrent neural network) kullanarak omurilik bölgesindeki gri ve beyaz maddenin bölütlenmesini sağlamışlardır. Elde edilen sonuçlara göre nörodejeneratif hastalıkların değerlendirilmesinde omurilik bölütlemesi için daha hassas ve otomatik bir yaklaşım olanağı sunmakla beraber önerilen yeni yöntem ile omurilik MR görüntülerinin analizinde doğruluk ve hassasiyeti arttırarak klinik ve araştırma amaçlı kullanım için oldukça verimli bir çalışma gerçekleştirilmiştir. Çalışma, MD-GRU modelini eğitmek için 855 omurilik MR görüntü dilimi kullanarak önceki yöntemlere kıyasla önemli iyileştirmeler göstermiş ve klinik ve araştırma uygulamaları için umut verici bir araç olduğunu ortaya koymuşlardır.

Diğer bir taraftan derin öğrenme ile yapılan çalışmalar büyük bir hız kazanmış olup evrişim ağların ile ilk çalışmalar yapılmaya başlanmıştır. Bu çalışmalardan birinde McCoy ve arkadaşları (McCoy vd., 2019: 737) tüm omurilik bölgesini ve intramedüller omurilik lezyonlarını tespit etmişlerdir. Bu yöntemde 24 saat içerisinde omurilik yaralanması geçirmiş 47 hastadan elde edilmiş aksiyel T2a 3T MR görüntüleri kullanılarak bir veriseti hazırlamışlardır. Geliştirilen yeni 2B-CNN mimarisini kullanarak tüm omurilik ve intramedüller omurilik lezyon bölgelerin tespit edilmesini sağlamışlardır. 3 farklı modeli kıyaslayarak kullandıkları modellerin başarısı arasında çok bir fark olmamakla beraber modellerin derin bir ağ yapısına sahip olmaması elde ettikleri sonuçları etkilediği vurgusu yapılmıştır. Elde ettikleri sonuçları diğer bölütleme araçları ile kıyaslayarak sonuçları değerlendirmişlerdir. BASICseg ismini verdikleri 2B-CNN

modeli ile akut omurilik yaralanma popülasyonunda mevcut bölütleme araçlarına kıyasla daha iyi performans sergilediği ve otomatik lezyon bölütlenmesinden elde edilen yaralanma hacimleri, akut fazdaki motor bozukluklarının ölçümleriyle bağlantısı tespit edilmiştir. Bu çalışmanın bulguları, omurilik yaralanma vakalarında, tanı ve tedavi sürecinde doğru ve hızlı bir şekilde değerlendirilmesine önemli katkı sunacağı düşünülmektedir. Ayrıca motor fonksiyon bozuklukları ile ilişkili biyoişaretçilerinin tespiti için derin öğrenme yöntemlerinin etkinliğinin oldukça yüksek olduğu sonucu elde ettikleri diğer bir çalışma çıkıtısı olarak belirtmişlerdir.

Omurilikte kordoma adı verilen tümörün otomatik olarak bölütlenmesi için yapılan çalışmada Reza ve arkadaşları (Reza vd., 2019: 487) 8 hastadan alınan 22 sagittal açıdan çoklu kontrastlı MR görüntüleri kullanılarak oluşturulan veri seti ile iki adımlı 3 boyutlu CNN kullanılarak ilgili tümör alanı tespit edilmiştir. Birçok tümör gibi kordoma tümörlerinin konumları, boyut ve şekil bakımından farklı görünüşleri nedeniyle otomatik bölütlemeleri zorlu bir iş olarak belirtmişlerdir. Modelin ilk aşamasında tüm potansiyel tümör voksellerini tespit etmeyi öğrenirken, ikinci aşamada gerçek tümör voksellerini birinci ağ tarafından tespit edilen yanlış pozitiflerden ayırt etmek için sınıflandırıcıya ince ayar yapması sağlanmıştır. Derin öğrenme uygulamaları için model başarılarının daha iyi analiz edilmesi için veri adedinin yüksek olması gerekliliği var iken bu çalışmada 8 kişiden veri temin edilmiş olması elde edilen başarıların düşük olmasına bir gerekçe olarak gösterilmiştir.

Derin öğrenme alanında geliştirilen Resnet-50 mimarisi kullanılarak yapılan diğer bir çalışmada ise Merali ve arkadaşları (Merali vd., 2021: 10473) dejeneratif servikal miyelopati (DCM, Degenerative cervical myelopathy) tanılı hastalarında servikal omurilik sıkışmasını belirleyebilmek için yeni bir model geliştirmişlerdir. Model eğitimlerinde T2 MR verileri kullanmış olup yüksek sonuçlar elde edilmiştir. Fakat yazarlar modelin daha iyi performansa sahip olması için sadece dejeneratif servikal miyelopati hastalarının verilerine ek olarak asemptomatik hastaların veya hafif DCM semptomları olan hastaların verilerinin model eğitime dahil edilmesinin daha genelleştirilebilir bir modelle sonuçlanabileceğinden bahsetmektedirler. Ek olarak yapılan etiketleme yönteminin bir kısıt olduğu vurgusu yapılmıştır. Bu model sayesinde, servikal MR taramalarının yorumlanmasının verimliliğini ve nesnelliğini artırabileceği ve birinci basamak sağlık hizmetlerinde görüntülerin ilk yorum aşamasına entegre edilmesinin zaman ve insan kaynağı açısından olumlu etki sunacağı değerlendirilmiştir. Model eğitimleri sonunda dejeneratif servikal spinal kord kompresyonunu doğru bir şekilde

tespit edilmesinin klinik karar vericilerin daha hızlı ve etkili hastalık süreçlerini değerlendirmelerine önemli bir katkı sunabileceği vurgusu yapılmıştır.

Diğer bir çalışmada ise Perone ve arkadaşları (Perone vd., 2018: 1) canlıda ve canlı dışında (in vivo ve ex vivo) MR veri seti kullanılarak derin öğrenme modeli ile gri bölgenin bölütlenmesini önermişlerdir. Geliştirdikleri derin öğrenme modelinde Atrous Uzaysal Piramit Havuzu (ASPP, Atrous Spatial Pyramid Pooling) adı verilen ve dilatasyonlu konvolüsyonların kullanıldığı özel bir mimari oluşturmuşlardır. Genişlemeli (dilatasyonlu) konvolüsyonlar, daha az parametre kullanarak alıcı alanı önemli ölçüde genişletmekte ve bu ağın verimliliğini artırmaktadır. Bu yöntemde, farklı genişleme oranlarına sahip paralel dallar kullanılarak çok ölçekli özellikler yakalanabilmekte ve bu sayede bölütleme doğruluğu artırılabilir. Çalışmada 6 bağımsız metot ile elde edilen çıktılar karşılaştırılmıştır. 10 farklı değerlendirme metriği içerisinde 8 tane metrik de daha yüksek performans elde edilmiştir. Modelde kullanılan 2B bağlam bilgisine ek olarak 3B bağlam bilgilerinin de olmasının daha iyi sonuçlar elde edilebileceği fikri savunulmuştur. Fakat ek olarak bu yöntem ile geleneksel tıbbi görüntüleme mimarilerine kıyasla daha az parametre kullanarak daha iyi sonuçlar elde etmeyi başarmışlardır. Bu çalışma, ALS (Amyotrofik Lateral Skleroz) gibi nörolojik bozukluklarla ilişkilendirilen gri madde değişikliklerinin otomatik olarak bölütlenmesinin klinik süreçlerine önemli ölçüde katkı sağlayacağı vurgusu yapılmaktadır.

U-Net mimarisi görüntüler üzerinde segmente edilecek özel bölgenin çıkarılmasını gerçekleştirir ve gelişmiş özellik seçimi ile diğer derin öğrenme modelleri ile kıyaslandığında daha az veri ile daha üstün performans göstermektedir. Derin öğrenme de özellikle tıbbi görüntüleme alanında kullanmak için geliştirilen ve birçok açıdan kararlı ve güçlü sonuçlar veren U-Net modelleri kullanılarak farklı planelerden taranmış MR görüntüleri kullanılarak omurilik bölgesi(Xiaoran Zhang vd., 2021: 104345), (AskariHemmat vd., 2019: 115), (Hille vd., 2020) ve omurilik tümör ve lezyonlarının(Lemay vd., 2021: 102766), (Zhuo vd., 2022: e210292) otomatik bölütleme ile ilgili yapılmış çalışmalar bulunmaktadır.

Diğer bir çalışmada Xiaoran Zhang ve arkadaşları (Xiaoran Zhang vd., 2021: 104345) servikal spondilolitik miyelopati hastalarından aksiyel açıdan taranmış 3B Spine MR verileri ile oluşturulan bir veriseti üzerinde yoğun bağlantı yapısına sahip U-Net mimarisi kullanılarak omur sınır alanının belirlenmesini hedeflemektedirler. Önerdikleri U-Net mimarisi ile özelliklerin çıkarılmasını sağlayarak Inter-Slice Attention (ISA) Modülü ile de gelen bilgileri kullanarak bölütleme sonuçlarını iyileştirmek ve daha

kararlı bir bölütleme elde etmek çalışmanın ana motivasyonu olarak sunulmuştur. Deneysel sonuçlar, SAU-Net'in inter-slice attention modülünün (ISA) etkinliğini ve yöntemin diğer derin öğrenme yöntemlerine kıyasla daha yüksek doğruluk ve verimlilik sağladığını gösterilmektedir. Özellikle, bu yöntem omurga kanal stenozu, disk herniasyonu (fitik) ve dejenerasyonu gibi hastalıkların tespitinde ve morfolojik araştırmalarda kullanılabileceği belirtilmektedir.

U-Net mimarisi kullanılarak gerçekleştirilen diğer bir çalışmada AskariHemmat ve arkadaşları (AskariHemmat vd., 2019: 115) sabit nokta niceleme yöntemi (fixed point quantization metot) önerilmiştir. Farklı ağırlıklar ve aktivasyon fonksiyonları (ReLU, Tanh) için üç farklı tıbbi görüntüleme veriseti üzerinde performansları kıyaslamışlardır. Makalenin ana amacı derin öğrenme modellerinin bellek tüketimini ve hesaplama süresini azaltmayı amaçlayan yeni bir yöntemi önermektedirler. Bu bağlamda yaptıkları 4 bit ağırlık güncellemeleri ve 6 bit aktivasyonlar kullanarak bellek gereksinimlerinde 8 kat azalma sağlamayı başarmış olup elde edilen doğrulukta küçük ölçekle bir kayıp yaşandığı ifade edilmiştir. Önerdikleri sabit nokta kuantizasyonunu diğer tekniklerle karşılaştırdıklarında, GM (Spinal Cord Gray Matter Segmentation), EM (Electron Microscopic) ve NIH (National Institute of Health) veri setleri üzerinde daha doğru ve aynı zamanda daha tutarlı sonuçlar elde edildiğini ifade etmişlerdir. Bu yöntem, özellikle sınırlı bellek ve hesaplama kaynaklarına sahip cihazlarda kullanılmak üzere derin öğrenme modellerini daha verimli hale getirme potansiyeline sahip olduğu belirtilmektedir.

U-Net ile yapılan diğer bir çalışmada Hille ve diğerleri (Hille vd., 2020) MR görüntüleri ile omurga metastazlarını segmentlere ayırmışlardır. Araştırmacılar 40 klinik vakada hem litik hem de sklerotik lezyon tiplerini (lytic and sclerotic lesion types) ve farklı MR sekansları kullanılarak özel sayılarda katman yapıları içeren U-Net benzeri bir mimari kullanarak otomatik bölütleme yöntemi önermişlerdir. Model eğitimleri sonunda uzman düzeyine yakın bölütleme doğruluğu elde edildiği belirtilmiştir. Bu bağlamda yapılmış başka bir çalışma olmamasının çalışmada elde edilen sonuçların performans karşılaştırması açısından eksik kaldığı vurgulanmıştır.

Omurilik ve bu bölgedeki tümörün, ödemin ve kavitenin (the tumor, edema and cavity) tespit edilmesi için kaskat yapıya sahip bir U-Net modelinde, Lemay ve diğerleri (Lemay vd., 2021: 102766) öncelikle omur bölgesinin lokasyonunun belirlemişler ve ikinci aşamada ise tümör, ödem ve kavite alanlarının tespit edilmesi sağlamışlardır. Çalışmada 343 hastadan elde edilen gadolinyum ile güçlendirilmiş T1a ve T2a MR

verileri kullanılmıştır. En yaygın üç omurilik içi tümör tipi olan astrositomlar, ependimomlar ve hemanjioblastomlar incelenerek maske verisi oluşturulmuştur. Önerilen kaskad(ardıl) U-Net modeli ile ilk aşamada model omuriliğin sınır alanları bulunmaktadır ve sınırlayıcı kutu koordinatlarını oluşturulmaktadır. İkinci aşamada ise bu sınırlayıcı kutulara göre görüntüler kırılarak tümörlerin bölütleme işlemleri gerçekleştirilmektedir. Önerilen kaskad bir mimarinin seçimi ile daha hızlı eğitim, daha hızlı tahmin yeteneği ve yüksek dice skoru elde etmeyi hedeflemişlerdir. Çalışmada belli bir performans başarımı elde edilmiş olup, çalışmanın tek bir uzman tarafından işaretlenmiş olması, yalnızca intramedüller tümörler üzerinde eğitilmiş olması, yüksek sınıf dengesizliği çalışmanın kısıtları olarak belirtilmiştir. Bu çalışma ile omurilik tümörü bölütleme alanında önemli bir çalışma olduğu ve klinik uygulamalarda kullanılabilirliğinin öneminden bahsetmektedirler.

Farklı derin öğrenme ağlarının kullanıldığı bir diğer çalışmada ise Zhuo ve arkadaşları (Zhuo vd., 2022: e210292) omurilik lezyonu bölütleme ve sınıflandırması için yeni bir yöntem önermişlerdir. MR verilerinde sıklıkla benzer özellikler sergileyen intramedüller omurilik tümörleri ve inflamatuvar demiyelinizan lezyonların ve bunların alt tiplerinin doğru şekilde ayırt edilmesi için yapılan çalışma kapsamında çok geniş ölçekli veri seti hazırlamışlardır. Retrospektif olarak 490 hastadan; 118 astrositom, 130 ependimom, 101 MS, ve 141 nöromyelitis optika spektrum bozukluğu (NMOSD) T2a MR görüntüsü oluşturulurken prospektif olarak ise 157 hastadan; 34 astrositom, 45 ependimom, 33 MS, ve 45 NMOSD T2a MR görüntüsü kullanılmışlardır. Araştırmacılar yöntem olarak iki boyutlu MultiResUNet ve DenseNet121 ağlarına dayanan bir sınıflandırma ve bölütleme modeli geliştirmişlerdir. Deneysel çalışmalar sonucunda her bir hastalık grubu için ayrı ayrı performans sonuçları elde etmişlerdir. Klinik pratikte manuel bölütlemenin zaman alıcı ve hata yapma olasılığının yüksek olması nedeniyle model eğitimleri sonucunda yüksek doğruluk ile ilgili bölgelerin tespit edilmesinin gelecekte radyologlara yardımcı araçlar olarak kullanılabileceğini göstermesi açısından oldukça önemli olduğu belirtilmektedir. Birbirine çok benzer doku benzerlikleri gösteren tümör grupları olmalarına karşılık bu iki tür lezyonun tedavi ve prognozu farklıdır, bu nedenle doğru bir ayırım yapılması tedavi süreci için çok kritik bir detay olarak belirtilmiştir.

Bir diğer çalışmada, Alsenan ve arkadaşları (Alsenan vd., 2021: 244) SCGM verisetini kullanarak omurilik gri bölgenin tespit edilmesini sağlamak için U-Net ve MobileNetV3 mimarilerinin birleşimine dayalı bir yöntem önermişlerdir. Bu

çalışmada, MobileNetV3 modelinin bir dizi blok kullanarak özellik haritaları üreten ve bu haritaları optimize eden bneck blokları, sıkma ve uyarma (SE, squeeze-and-excitation) modüllerinden faydalanılmışlardır. Ayrıca modele upsampling katmanları ve atlama bağlantıları ekleyerek MobileNetV3'ün U-Net benzeri bir model haline getirilmiştir. Çalışmada önerilen model ile en güncel yöntemlerle de kıyaslaması yapılarak sonuçların değerlendirilmesi sağlanmışlardır. MobileUNetV3, nörolojik bozuklukların teşhisi ve tedavisinde önemli bir araç olarak kullanılabileceği ve MR verileri üzerinde etkin bir şekilde çalışarak, gri madde dokusunun ayrıntılı bir şekilde analiz edilebileceği önermektedirler. Klinik olarak zor bir alan olan spinal kord gri madde bölütleme konusunda önemli bir ilerleme sunmakta ve bu alanda gelecekte yapılacak çalışmalar için güçlü bir temel oluşturulduğu vurgusu çalışma kapsamınca yapılmıştır.

Fei ve arkadaşları (Fei vd., 2023: 817) yaptıkları çalışmada servikal spondilotik miyelopati hastalarının derin öğrenme temelli bölütleme yöntemi kullanılarak ilgili bölgenin segmente edilmesi sağlanmıştır. Hastalığın tanı ve tedavi süreçlerinde kullanılan bir tür manyetik rezonans görüntüleme tekniği olan difüzyon tensör görüntüleme (DTI, diffusion tensor imaging) kullanılmıştır. DTI verilerinden elde edilen ve dokuların mikroyapısal özelliklerini yansıtan bir metrik olan FA (fraksiyonel anizotropi) değeri kullanılmaktadır. Çalışmada, 89 servikal spondilotik miyelopati hastasından elde edilen toplam 1159 kesit analiz edilerek fraksiyonel anizotropi (FA) haritaları hesaplanmıştır. Lateral, dorsal, ventral ve gri madde bölgeleri, her iki yandan kapsayan sekiz farklı ilgi alanı (ROI, region of interest) belirlenerek eğitim sonuçlarında elde edilen metrik değerlerini manuel ve ön eğitilmiş VGG16 and ResNet50 back bone U-Net modeli ile kıyaslamışlardır. Çok fazla zaman alıcı manuel işaretleme yerine önerilen otomatik bölütleme modeli ile servikal omuriliğin daha detaylı bir şekilde analiz edilmesine ve durumunun daha ayrıntılı olarak nicel hale getirilmesine olanak tanımaktadır. Bu çalışmanın sonuçları, servikal spondilotik miyelopati tanı ve tedavisinde DTI ile elde edilen verilerin otomatik olarak işlenmesiyle klinik süreçlerin hızlandırılabilceğini ve daha doğru teşhisler konulabileceğini göstermektedir.

Diğer bir çalışmada Zhang ve arkadaşları (Xiang Zhang vd., 2022: 1081441) servikal omurilik MR görüntülerinin bölütleme tekniklerini iyileştirmeyi amaçlayan geliştirilmiş bir U-Net derin öğrenme modeli olan SeUneter mimarisini önermektedir. Araştırmada 300 hastadan alınan 600 T2a MR görüntüsü kullanılarak bir veriseti hazırlanmıştır. Bu görüntüler, servikal vertebra cisimleri, intervertebral diskler, spinal kanal ve spinal kord gibi ayrıntılı yapıları içermektedir ve toplamda 16 kategori (arka

plan dahil) kapsamaktadır. Attention modülü U-Net mimarisinin çift konvolüsyon katmanlarına entegre edilerek daha ayrıntılı özelliklerin çıkarılmasını sağlaması hedeflenmiştir. Farklı derin öğrenme modelleri ile sonuçlar kıyaslandığında daha üstün sonuçlar elde edilmiştir. SeUneter, servikal omurga MR bölütlemesinde attention bağlantılarını kullanarak daha doğru ve verimli bölütleme sağlayan yenilikçi bir yöntem olarak değerlendirirken özellikle klinik ortamda omurga hastalıklarının tanısında ve takibinde önemli bir araç olabileceği vurgusu yapılmaktadır.

Tablo 2.1.'de geleneksel ve derin öğrenme yöntemlerini içeren omurilik sınırları ve farklı omurilik lezyonlarının tespit edilmesini içeren literatür çalışmalarının kısa bir özeti sunulmuştur.

Tablo 2.1. Geleneksel ve derin öğrenme yöntemlerini içeren omurilik sınırları ve farklı omurilik lezyonlarının tespit edilmesini içeren literatür çalışmaları

Çalışma	Sistem	Metodoloji	Veri Seti	Veri sağlayıcısı
Geleneksel Metotlar				
El Mendili vd. (2015)	El yordamı /Yarı-oto	ROI	MRI T2a	Sağlıklı, ALS, SMA, SCI
El Mendili vd. (2015)	Yarı-oto	Double-thresholding (DTbM)	MRI T2a	Sağlıklı, ALS, SMA, SCI
Losseff vd. (1996)	Yarı-oto	Intensity-based thresholding and region-growing segmentation	MRI T1-like (FSPGR)	Sağlıklı, MS
Tench vd. (2005)	Yarı-oto	Edge detection + PV correction	MRI T1a	Sağlıklı
Horsfield vd. (2010)	Yarı-oto	Active Surface	MRI T1a, T2a	Sağlıklı, MS
Kawahara vd. (2013)	Yarı-oto	PCA	MRI T1a, T2a	Sağlıklı, MS
Law vd. (2013)	Yarı-oto	Two points Gradient competition descriptor with orientation coherence + intensity classification	MRI T1a, T2a	Sağlıklı
Sabaghian vd. (2020)	Oto	K-Means	MRI T2a	Yaralanmamış gönüllü
Gros vd. (2018)	Oto	OptiC	MRI T1, T2, T2*, difüzyon ağırlıklı	20 farklı merkezden nörolojik hasta
Koh vd. (2010)	Oto	Active contour(GVF)	MRI T2a	Sağlıklı
Chen vd. (2013)	Oto	Atlas registration with topology constraint	MRI T1a, T2a	Sağlıklı, MS
Pezold vd. (2015)	Oto	Continuous max-flow with cross-sectional similarity prior	MRI T1a	Sağlıklı, MS
Asman vd. (2014)	Oto	Multi-atlas label fusion	MRI T2a	Sağlıklı
De Leener vd. (2015)	Oto	Single-atlas deformation(MNI-Poly-AMU şablon)	MRI T2,T2a	Sağlıklı
Taso vd. (2015)	Oto	Tensor tabanlı morfometri (TBM) (AMU40 şablon)	MRI T2a	Sağlıklı
De Leener vd. (2015)	Oto	PropSeg	MRI T1a, T2a	


Tablo 2.1.'in devamı

Gros vd. (2019)	Oto	2B Dilate CNN+3B CNN	MRI T1, T2, T2a	Sağlıklı, MS, Diğer
Horváth vd. (2019)	Oto	MD-GRU (New RNN)	AMIRA MR (Özel protokol)	Sağlıklı
McCoy vd. (2019)	Oto	2B-CNN	MRI T2a	Omurilik Yaralı
Reza vd. (2019)	Oto	3B-CNN	MRI T2a	Kordoma tümör
Merali vd. (2021)	Oto	ResNet-50	MRI T2a	dejeneratif servikal miyelopati
Perone vd. (2018)	Oto	CNN (Atrous Spatial Pyramid Pooling (ASPP))	MRI Flair, T1a, T2a	ALS
Koh vd. (2011)	Oto	an attention model and an active contour model		
U-Net				
Zhang vd. (2021)	Oto	Sau-net	MRI T2a	Servikal spondilolitik miyelopati
AskariHemmat vd. (2019)	Oto	U-Net (sabit nokta niceleme yöntemi (fixed point quantization metot))	Spinal Cord Gray Matter Segmentation, ISBI challenge, National Institute of Health (NIH)	
Hille vd. (2020)	Oto	U-Net	MRI T1, T2, T2a	Sağlıklı, MS, Diğer
Lemay vd. (2021)	Oto	Kaskad U-Net	MRI Gadolinium-enhanced T1a T2a	Tümör, Ödem ve Kavite
Zhuo vd. (2022)	Oto	MultiResUNet ve DenseNet121	MRI T2a	Astrositom, Ependimom, MS
Alsenan vd. (2021)	Oto	MobileNetV3 ve U-Net	SCGM	Diğer
Alsenan vd. (2022)	Oto	MobileNetV3 ve U-Net	SCGM	Diğer
Fei vd. (2023)	Oto	U-Net (backbone with VGG16 and ResNet50)	Diffusion tensor imaging (DTI) MRI)	Servikal spondilolitik miyelopati
Zhang vd. (2022)	Oto	SeUneter	MRI T2a	Diğer

ALS:Amiyotrofik lateral skleroz
SMA:Spinal musküler atrofi
SCI: Spinal cord injury
MS:Multipl skleroz
SSS:Santral sinir sistemi
MRI:Manyetik rezonans image
PCA: Principal component analysis

3. OMURİLİK VE YAPISI

Omurilik, beyinle birlikte merkezi sinir sisteminin önemli bir parçasıdır. İnsan omuriliği merkezi sinir sisteminin oldukça organize ve karmaşık bir parçasıdır. Omuriliğin işlevi nöral sinyallerin, beyinden (duyusal bilgi) periferik sinir sistemine (motor bilgisi) ve periferik sinir sistemden beyne iletilmesini sağlamaktır. İletilen bu bilgi BM bulunan miyelinli motor ve duyusal aksonlardan geçer ve çoğunlukla GM bulunan omurilik internöronlar tarafından iletilir ve kontrol edilir(De Leener vd., 2016: 125).




Şekil 3.1. Omurilik vertebra anatomisi

Kaynak: (Altman ve Bayer, 2001)

Omurilik omurlar arasındaki kemik bir kanal içinde olup omuriliğin çevresi BOS adı verilen beyin omurilik suyu ile çevrilidir. Omurilik, beyin ile periferik sinir sistemi arasındaki bağlantıdan sorumlu olan ana bağlantısı sağlamaktadır. Yaklaşık 40-45 cm uzunluğunda, 1 cm çapında, 30 gr. Ağırlığındadır(Duman, 2009). Kadınlarda 1-2cm daha uzundur. Şekil 3.1.'de görüldüğü gibi, omurilik temel olarak servikal vertebra (boyun omuru, 7), torasik vertebra (sırt omuru, 12), lomber vertebra (bel omuru, 5), sakral vertebra (sakrum, 5) ve koksigeal vertebra (koksiks, 4) olmak üzere ilk 24 adet eklem birbirine bağlı olup tüm alana presakral vertebra denilmektedir. Diğer sakral ve koksiks alana ise pelvik bölge ismi verilmektedir.

Omurilik aksiyel (transvers) kesitte incelendiğinde dış bölümünde miyelinli akson demetlerinden oluşan beyaz madde (ak madde, beyaz cevher) var iken iç bölümünde gri madde (boz madde, gri cevher) bulunmaktadır. Omurilik gri madde ve beyaz madde adı verilen bu iki temel sinir dokudan oluşmaktadır(Paugam vd., 2019: 21). Şekil 3.2.'de görüldüğü gibi, gri madde H harfine benzetilmekte veya literatürde “kelebek” şeklinde ifadesi kullanılmaktadır. Omurilik boyunca gri madde ve beyaz madde yapısı incelendiğinde hacimsel ve şekil bakımından değişiklik göstermektedir. Omuriliğin gri ve beyaz maddenin sahip olduğu hacimsel değişiklikler veya doku deformasyonları birçok nörolojik hastalık sebebiyet vermektedir(Amukotuwa ve Cook, 2007: 511).



Şekil 3.2. Omurilik aksiyel kesitte beyaz madde ve gri madde yapısı

Kaynak: (Altman ve Bayer, 2001)

Bu dokulardaki beyaz ve gri maddede demiyelinizan plaklarının birikmesi ile beyin, omurilik ve optik sinirleri etkileyerek MS gibi birçok hasarlı dokunun oluşmasına sebep olmaktadır. Bu nedenle omurilik MR görüntüleme ile MS, ALS ve travmatik yaralanma gibi çeşitli hastalıkların araştırılmasında hayati bir rol oynamaktadır.

3.1. Omurilik MS Lezyonları

Multipl Skleroz (MS), merkezi sinir sisteminin kronik, inflamatuvar, demiyelinizan, nörodejeneratif bir hastalığıdır(Grigoriadis ve Van Pesch, 2015: 3),(Mortazavi vd., 2012: 299). MS, beyin, omurilik ve optik sinirleri etkilemekte olup beyaz ve gri madde de demiyelinizan plaklarının birikmesi ile oluşan az da olsa aksonların ve nöron hasarlarının görüldüğü bir hastalıktır türüdür(S. Öztürk vd., 2017: 137). Sinir ağları miyelin kılıflar sayesinde bir nörondan diğerine iletilmesi gereken

sinyalleri hızlı bir şekilde iletilmesini sağlamakla beraber bu miyelin kılıfın hasarından (demyelinizasyon) sinir sistemi boyunca iletimde aksaklıkların yaşanmasına sebep olmaktadır(Zeng vd., 2020: 610967). Bu aksamalar ise vücut fonksiyonlarının bozulmasına neden olur(Mortazavi vd., 2012: 299). MS oldukça heterojen bir hastalık olup santral sinir sisteminin etkilendiği bölgeye göre motor, duyu, otonom ve kognitif bozuklukları içeren çok değişken klinik belirti ve bulguları olabilmektedir(Christogianni vd., 2018: 208).

MS hastasının yaşamını fiziksel, ekonomik, psikolojik ve sosyal yönleriyle etkileyebilen, sıklıkla özürllülüğe yol açan kronik bir hastalıktır(Yıldırım ve Fadiloğlu, 2014: 100). Çeşitli semptomların varlığı ve öngörülemez doğası nedeniyle hastalar gelecekleriyle ilgili belirsizlikle yaşamak zorunda kalmakla beraber ilerleyen evrelerde nörolojik morbidite ve mortaliteye sebep olabilmektedir(Lemay vd., 2021: 102766). İlk olarak 1868 yılında Jean-Martin Charcot tarafından yeni bir sinir sistemi hastalığı olarak bildirilmiştir (Zalc, 2018: 3482) ve ardından Schumacher (1965), Poser (1983) ve McDonald (2001) MS için klinik tanı kriterleri yayınlamışlardır. McDonald Kriterlerinde MS hastalığı için bir dizi değerlendirme ölçütü sunulmuştur(Thompson vd., 2018: 162). Bu ölçütler zaman içerisinde revize edilerek günümüzde de en sık kullanılan değerlendirme kriterlerinden biri haline gelmiştir(Toğrol ve Demir, 2013: 15).

MS lezyonları omurilik servikal, torasik ve lomber olmak üzere tüm kord boyunca gözlemlenebilmekle beraber sıklıkla servikal omurilikte (%56,4) daha fazla gözlemlenmektedir ve bu nedenle klinik çalışmalarda MS lezyonları MR taramalarında genellikle servikal bölgede aranmaktadır(Bot vd., 2004: 226),(Patek ve Stewart, 2023: 406). Geçmişten günümüze çok hızlı gelişim gösteren MR teknolojisi sayesinde nokta atışı klinik tanı ile cerrahi işlemler yapılabilmektedir(Karkucak ve Köksal, 2021: 147). MR teknolojisinin sağladığı kolaylıkların yanı sıra görüntülenecek omurilik alanının sahip olduğu farklılıklar bölgesel zorluklar veya patolojik nedenler tıbbi görüntülemenin çekim kalitesini etkileyerek optimumun altında bir performans göstermesine sebep olabilmektedir(Stroman vd., 2014: 1070),(De Leener vd., 2016: 125).

3.2. MS’de Epidemiyoloji

MS ile ilgili olarak 70 yıldan fazla zaman diliminde yapılan çalışmalardan elde edilen veriler ile epidemiyolojik olarak bir veri zenginliğine ulaşılmıştır. Fakat dünya genelinde MS’in coğrafi dağılım modelini çıkarmak hala zor bir iştir(Pugliatti vd., 2002: 182). Yapılan istatistiksel çalışmalarda ortak kriterlerin kullanılmaması; araştırılan popülasyonların değişkenliği, vakaların hangi evrelerde oldukları, coğrafi ve zaman

değişkenlerine bağlı olarak tedaviye erişim imkanlarının değerlendirilme kriterleri, farklı tanı kriterlerinin kullanılması gibi diğer başlıca kritik sorunlardandır. Bu nedenle ortak zaman diliminde taranmış genel bilgiye ulaşmak zor olmakla birlikte son yapılan değerlendirmeler yaklaşık veya genel ifadeler kullanılmaktadır. Bu bakımdan incelendiğinde Dünya sağlık örgütünün son verilerine göre dünyada 2,5 milyondan fazla kişinin MS hastası olduğunu ve tüm yaş aralıklarında gözlemlenmekle beraber genç erişkinlerde ve özellikle kadınlarda daha sık gözlemlendiğini belirtmişlerdir(Nouri vd., 2015: E675). MS ile ilgili olarak yapılan araştırmalarda köken, kıta, yaşanan coğrafi bölge, cinsiyet, yaş aralığı, gün ışığı süresi, beslenme şekillerine vb. gibi birçok açıdan yapılan çalışmalar mevcuttur. Bunlardan bazılardan elde edilen verilere göre; Türkmenler, Özbekler, Kazaklar, Çinliler, Japonlar, Afrikalı siyahlar vb. gibi ırklarda daha nadir izlenirken Parsiler ve Filistinlilerde daha fazla gözlemlenmekte olduğunu belirtmişlerdir(Pugliatti vd., 2002: 182). Aynı bölgede yaşayan farklı ırklarda da farklı sonuçlar elde edildiği gözlemlenmiştir. Bu nedenle genel bir çıkarımla MS hastalığının yaşanan yer ile ilgili değil daha çok kişisel bir hastalık olması yorumunda bulunulmuştur(Pugliatti vd., 2002: 182). Dünyada yapılan çalışmalar ışığında çıkarılmış MS haritasına ait bir veriyi Şekil 3.4'te gösterilmektedir.



Şekil 3.4. MS dünya geneli prevalansı haritası

Kaynak:(Pugliatti vd., 2002: 182)

3.3. MS Etiyolojisi

MS etiyojisi tam olarak bilinmemekle birlikte, otoimmünite, genetik yatkınlık ve çevresel faktörlerin tamamının hastalığı tetikleyen unsurlar olduğu bilinmektedir(Weinshenker, 1996: 291),(Sawcer vd., 1996: 464). MS otoimmün hastalık grupları içerisinde değerlendirilmektedir(Mirza, 2002: 40). Otoümmün sistem vücudun bağışıklık sistemini oluşturan hücrelerinin kendi hücrelerine saldırması anlamına gelmektedir.

Viral enfeksiyonlar, bakteriyel enfeksiyonlar, beslenme alışkanlığı, evcil hayvan besleme, travma, kaza veya ameliyat, aşılar, gebelik, iklim koşulları gibi bazı parametrelerin etiyojideki rolleri üzerinde oldukça geniş araştırmalar yapılmasına rağmen ortak bir görüş elde edinilememiştir(Sadovnick ve Ebers, 1993: 17). Diğer taraftan hayvansal yağ et tüketimi gibi beslenme şekillerinin MS ile olan ilişkisi incelendiğinde farklı sonuçlar elde edilmiştir(Granieri, 2000: S141). İklim şartları, kıta, yaşanan coğrafi bölge, ırk, cinsiyet, yaş aralığı, gün ışığı süresi (D-vitamin), sosyo kültürel seviye, meslek seçimi, aşılar zararlı alışkanlıklar (sigara, alkol vb.), yüksek oranlarda kahve tüketimi gibi birçok açıdan yapılan çalışmalar olmasına rağmen bir koşula bağlı olmayan çok koşullu durumların değerlendirilmesi gereken bir hastalık olarak yorum yapılabilir. MS etiyojisini tüm bu çevresel koşulların ve yaşam standartlarının yanı sıra genetik alt yapısı da incelenmesi gereken kompleks bir hastalıktır(Olsson vd., 2017: 25). İkizlerde ve MS'lilerin birinci derece yakın akrabalarında MS'in daha sık görülmesi gibi nedenlerle genetik etkenlerin önemi giderek daha araştırılması gereken kritik bir konu olarak karşımıza çıkmaktadır. Buna ek olarak MS, beyaz ırkta daha fazla görülürken siyah ırkta nadir gözlemlenmektedir. Eskimolarda, Joponya, Çin ve Kore'de de oldukça nadir olarak MS tanısı alınmaktadır. Genetik çalışmaların ışığında bölgesel yapılmış birçok çalışma yapılmış olmasına rağmen kısaca MS, beyaz ırkta fazla tanı alırken Asya ve siyah ırkta MS tanısı alma riski daha düşük olduğu belirtilebilmektedir(Mirza, 2002: 40).

3.4. MS Belirtileri, Tanı ve Teşhisi

MS hastaları çok çeşitli sebeplere bağlı olarak yeni başlayan veya tekrarlayan nörolojik semptomlar için klinik başvurusu yapabilmektedirler. Fakat klinik semptomları ve bulguları oldukça değişkenlik göstermekte olup duysal, motor, görsel ve beyin sapı ile iletimi sağlayan yollarda meydana gelen hasarlardan dolayı kaynaklanabilmektedir.(Garg ve Bhagyashree, 2021: 229). Bunlardan bazıları ekstremitelerde güçsüzlük, duysal belirtiler, ataksi, mesane problemleri, yorgunluk,

diplopi, görme bulanıklığı gibi görsel belirtiler, dizatri, bellek-konsantrasyon-dikkat bozukluğu gibi kognitif yakınmalar sık görülen belirtilerdir. Buna karşılık hareket bozuklukları, epileptik nöbet, baş ağrısı, demans düzeyinde kognitif yıkım, kortikal belirtiler, işitme kaybı, amiotrofi seyrek görülen belirti ve bulgulardır(Ünal vd., 2018: 9).

Klinik olarak izole sendrom (Clinically Isolated Syndrome (CIS)) olarak adlandırılan bu hastalardaki ilk belirtiler optik nörit, inkomplet miyelit veya beyin sapı sendromu olabilmektedir(Miller vd., 2005: 281). Başlangıçtaki beyin veya omurilik MR görüntüleme ile tespit edilen klasik demiyelinizasyon lezyonlarının varlığının ikinci kez tekrarlanması durumunda MS varlığı için en önemli belirtilerinden biri olmaktadır (Filippi vd., 1994: 635). Diğer taraftan BOS anormalliklerinin tespit edilmesi elde edilen bulgulara ek olarak karar verici bir değere sahip olabilmektedir(Awad vd., 2010: 1). MS tanısı için geçmişten bugüne kadar edinilen klinik tecrübeler ışığında birçok bilgi birikimine ulaşılmış olmasına rağmen hala MS için tek bir tanısal test yoktur ve tanı genellikle MR görüntüleme ve bazı durumlarda BOS analizi ile desteklenen klinik seyrin takibine dayanmaktadır. İlk kez 1965 yılında Schumacher paneli ile kesin MS tanı kriterleri belirlenmiştir ve ardından Poser (1983) ve McDonald (2001) MS için klinik tanı kriterleri yayınlamışlardır. McDonald kriterleri klinik uygulayıcılar tarafından en çok kullan yöntemler bütünü olmuştur. 2001’de ilk hali ile uygulanmaya başlayan ve yıllar içerisinde revize edilerek 2017’de en güncel versiyonu elde edilmiştir(McDonald vd., 2001: 121),(Thompson vd., 2018: 162). MS teşhisi için başvuru McDonald Kriterlerinin son versiyonu Tablo 3.1’de verilmiştir.

Hastalık farklı seviyelere göre ifade edilmekte olup bazı seviyelerinde dönemsel ataklarla kendini gösterirken bir kısmında ise hastalığın başında veya son döneminde hızla ilerleyici bir süreç yaşanabilmektedir(M. Öztürk ve Tek, 2019: 10). Bu nedenle MS plaklarının sinir sisteminin farklı yerlerinde, farklı zamanlarda oluştuğunun gözlemlenmesi ile birlikte McDonald Kriterleri’nin vurguladığı önemli konulardan biri MS tanısı koyarken klinik takip için MRG (Manyetik Rezonans Görüntüleme)’in önemine özellikle vurgu yapılmaktadır(Thompson vd., 2018: 162). MR omurilik çekimleri ile MS hastalarının %80-%92 oranında teşhis edilebilmektedir(Bot vd., 2002: 46).

Tablo 3.1. Mcdonald Kriterleri 2017

Atak	Objektif Klinik Bulgulu Lezyon Sayısı (MRG)	MS Tanısı İçin Gerekli Ek Veri
≥2 atak	≥2	Yok ^a
≥2 atak	1+ öyküde başka bir alanda ki lezyona ait atak	Yok ^b
≥2 atak	1	MSS'de farklı bir alandaki lezyona ait yeni bir atak veya MRG ^c ile mekânda yayılımın gösterilmesi
1 atak	≥2	Ek bir klinik atak veya MRGd ile zamanda yayılımın gösterilmesi veya BOS-spesifik OKB varlığı
1 atak	1 lezyona ait objektif klinik bulgu	MSS'de farklı bir alandaki lezyona ait yeni bir atak veya MRG ^e ile mekânda yayılımın gösterilmesi ve ek bir klinik atak veya MRG ^d ile zamanda yayılımın gösterilmesi veya BOS-spesifik OKBe varlığı
Sinsi ilerleme	1 yıl klinik izleme (retrospektif veya prospektif, ataktan bağımsız olarak)	Aşağıdakilerin 2'si; • MS tipik alanlarda ≥1 lezyon • Spinal kord da ≥2 lezyon • BOS-spesifik OKB varlığı

^a : Mekanda ve zamanda yayılımı göstermek için ek bir teste gerek yoktur. Ancak beyin MRG tüm hastalara yapılmalıdır. Tanıyı destekleyecek yetersiz klinik ve MR bulguları olanlarda, tipik KİS olmayanlarda, atipik özellikleri olan hastalarda ek olarak spinal kord MRG ve BOS tetkiki yapılmalıdır. Bu tetkikler yapılmadıysa ya da negatifse MS tanısı koymadan önce dikkat edilmeli ve alternatif tanılar göz önünde bulundurulmalıdır.

^b : Atak için objektif nörolojik bulgular temelinde konulmuş klinik tanı en güveniliridir. Öyküdeki atağa ait dökümanite edilmiş objektif nörolojik bulgular yoksa, öykü enflamatuvar demyelinizan olaya ait tipik semptom ve klinik gelişim özelliklerini içermelidir. Ancak en az bir atak objektif bulgularla desteklenmelidir. Objektif kanıtların yokluğunda dikkatli olunmalıdır.

^c : MRG'de alanda yayılım; MS tipik (periventriküler, kortikal/jukstakortikal, infratentoryal ve spinal kord) 4 alanın ≥2'sinde ≥1 lezyon olması.

^d : MRG'de zamanda yayılım; herhangi bir zamanda çekilen MRG'de kontrast tutan ve tutmayan lezyonların aynı anda bulunması veya takip MRG'sinde ilk MRG (çekildiği zamandan bağımsız olarak) referans alındığında yeni bir T2 hiperintens lezyonun ya da kontrast tutan lezyonun olması.

^e : BOS-spesifik OKB varlığı zamanda yayılımı göstermez ama tanıda onun yerine geçer.


MS: Multipl skleroz, SSS: Santral sinir sistemi, MRG: Manyetik rezonans görüntüleme, BOS: Beyin omurilik sıvısı, OKB: Oligoklonal band (immünoglobulin bantları)

Kaynak: (Thompson vd., 2018: 162)

3.5. Servikal Omurilik ve MS'in MR ile Görüntülenmesi

MS tanısı koymak için tüm klinik değerlendirmelerin ardından en önemli yardımcı araç MR görüntülemesidir. McDonald Kriterlerine göre MS tanısı almak için klinik bulgular yeterli olsa bile MRG verisi alınmadan karar verilmemesine özellikle vurgu yapılmaktadır. Bunun en önemli nedeni ise demiyelinizan lezyonların sinir sisteminin farklı konumlarında farklı zamanlarda dilimlerinde oluşabilmesi olarak ifade edilmektedir (Toğrol ve Demir, 2013: 15). Bu sebeple farklı klinik seyir izleyen hastalarda yapılan MR tarama sonuçlarının kıyaslanması hastalığın ve lezyonların takibi için oldukça önemli olmaktadır.

Geçmişten günümüze MR cihazlarının ilk çekim gücü 0.02T iken gelişmeler ile birlikte 1T, 3T, 5T ve en son 7T çekim gücüne ve üzerinde bir çekim kalitesine ulaşmıştır. Bu sayede çekim süreleri kısalmış görüntüler daha da netleşmiştir. MR cihazları, farklı sekanslarda çekim yapabilmektedir. Şekil 3.5.'te görüldüğü gibi, omurilik MR görüntülerinin T1a, T2a, FLAIR gibi farklı sekanslarda ve sagittal, aksiyel ve koronal olmak üzere farklı açısal MR çekimleri yapılabilmektedir.

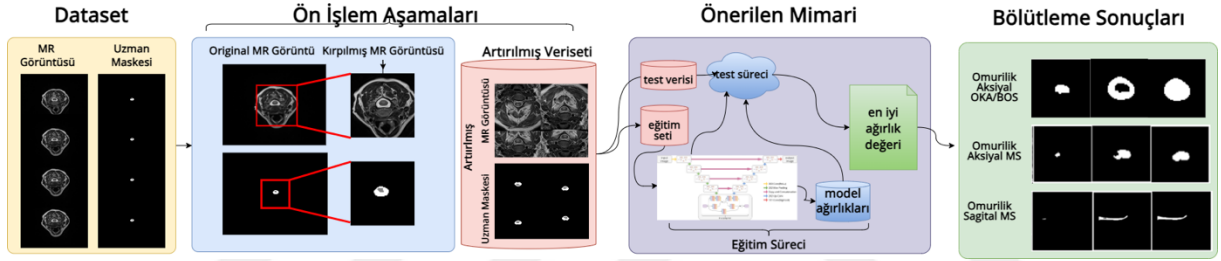


Şekil 3.5. Servikal ve torasik omurilik bölgesi T1a, T2a sagittal ve aksiyel MR verileri

MR görüntülerde incelenen omurilik lezyonları, omuriliğin yapısını ve fonksiyonunu etkileyen demiyelinizasyon, nöroaksonal kayıp ve gliosis alanlarına karşılık gelmektedir. Omurilik lezyonları, geleneksel spineko sekanslarında T2 hiperintensitesi alanları ve daha az sıklıkla T1 hipointensitesi alanları olarak görüntülenir (Moccia vd., 2019: 1756286419840593). MS lezyonları sıklıkla servikal bölgede (%59) ve daha az sıklıkla alt torasik omurilikte (T7-12; %20) görülür (Weier vd., 2012: 1560). Buna karşılık, MS'deki lezyonlar sagittal görüntülerde sıklıkla puro şeklinde/silindirik, aksiyel görüntülerde ise kama şeklinde görünür ve tipik olarak keskin sınırlara sahiptir (Filippi vd., 1994: 635). Sagittal görünümde uzunlukları nadiren iki vertebral segmenti aşar. Aksiyel taramalarda MS lezyonları kesit alanının %50'sinden azını tutar, tercihen lateral ve posterior beyaz cevher kolonlarını kaplar ve gri cevheri korumaz. Klinik ortamda omurilik MR'ı için önerilen protokoller hem sagittal hem de aksiyel taramaları içermektedir (Kim vd., 2015: 1165).

4. MATERYAL VE YÖNTEM

Tez kapsamında omurilik bölgesi bölütlenmesi ve omurilik MS lezyon tespiti için önerilen yapının genel blok diyagramı Şekil 4.1’de verilmekte olup diğer sagittal omurilik MS lezyonlarının tespit edilmesi ve aksiyel OKA/BOS alanlarının bölütlenmesi süreçleri aynı işlemler uygulanmaktadır. Sistem ilk olarak veri seti hazırlığı ile başlamaktadır. Veri seti hazırlığı genel anlamda uygun format dönüşümü, maske verilerinin oluşturulması, veri boyutlarının eşitlenmesi ve ihtiyaç halinde veri artırma işlemlerinin uygulanmasını kapsamaktadır. Daha sonra verilerin test ve eğitim olmak üzere ayrılarak kullanılacak olan U-Net mimarilerine karar verilmektedir. Model eğitimleri tamamlandıktan sonra ağırlıklar kaydedilerek literatürde sıklıkla kullanılan metrik değerleri hesaplanarak model başarıları değerlendirilmektedir. En son aşamada hedef bölütleme alanları için omurilik bölgelerinin bölütlenmesi veya omurilik MS lezyonlarının tespit edilmesi sağlanmaktadır.



Şekil 4.1. Servikal omurilik bölgesinin bölütlenmesi ve omurilik MS lezyonlarının tespiti için tez kapsamında önerilen yaklaşımın blok diyagramı


Omurilik bölgesinin otomatik bölütlenmesi ve omurilikte bulunan MS lezyonlarının otomatik tespit edilmesi, MS hastalığının takibinde çok önemli bir karar destek sistemi olarak kullanılabilir. Klinik ortamda omurilik MR'ı için önerilen protokoller hem sagittal hem de aksiyel taramaları içermektedir (Kim vd., 2015: 1165). Buna ek olarak omurilik bölgesinde MS lezyonları tanı ve tedavisi için çoğunlukla MS yoğunluklarının servikal bölgede olması nedeniyle omurilik servikal MR çekimi yapılmaktadır (Ünal vd., 2018: 9). Aksiyel T2 görüntülemenin özellikle daha fazla sayıda küçük ölçekli, periferik ve noktasal MS lezyonlarının tespitinde daha hassas iken sagittal T2 görüntüleme ile uzunlamasına lezyonların tespiti için daha uygun olabilmektedir vurgusu yapılmaktadır. Fakat bazı yapılan çalışmalarda ise sagittal MR verilerinde ise bazı vakalarda lezyonları yeterince hassas bir şekilde göstermediği ifade edilmiştir (Galler vd., 2016: 963). Özellikle aksiyel görüntülerde, omuriliğin yan bölgelerine yerleşen küçük lezyonlar daha net görüldüğü için tanı doğruluğu bakımından daha avantajlı durumda iken, sagittal kesitlerde bu tür lezyonlar daha az görünür olduğu

vurgusu yapılmıştır (Alcaide-Leon vd., 2016: 970). Ortak konsensus genel anlamda aksiyel ve sagittal görüntülemenin birlikte kullanılması olduğuna dikkat çekmektedir. Bu tez çalışmasında, aksiyel planelerden omurilik sınırları ve bu sınırlar içerisinde bulunan lezyonlar tespit edileceği için tüm kord boyunca (7'si servikal, 12'si torakal, 5'i lomber) MS lezyonları taramak yerine daha sık gözlemlendiği omurilik servikal bölge MR verileri kullanılmıştır(Wheeler-Kingshott vd., 2014: 1082). Diğer taraftan, tez çalışmasında, servikal omurilik bölütleme ve tespit etme işlemleri için U-Net mimarisi temelinde fractal evrişim yapısı kullanılarak geliştirilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarileri kullanılmıştır.

Tüm kullanılan verisetleri ile deneysel çalışmalar kapsamınca kullanılan ve geliştirilen U-Net mimarilerinin detayları tezin ilerleyen aşamalarında kapsamlı olarak sunulmuştur.

4.1. Verisetleri

Tıbbi görüntü işleme alanında sıklıkla kullanılan birçok veriseti olmasına karşılık omurilik gibi spesifik çalışılmak istenilen bölgelerde açık kaynak (publicly-available/açık kaynak) veriseti kısıtı bulunmaktadır. Bu nedenle çalışılmak istenilen spesifik organlar veya dokular için çalışmaya özgü veriseti oluşturmak bölütleme çalışmalarının zorlu fakat özgün olmasını sağlayan bir adımdır. Bu tez çalışması kapsamında bir global veriseti ve bir de çalışmaya özgü veriseti üzerinde deneysel çalışmalar yürütülmüştür. Bu bağlamda, özgün veriseti için Akdeniz Üniversitesi Hastanesi'ndeki MS hastalarından servikal omurilik bölgesine ait turbo spin echo sekansında T2a MR verileri toplanarak çalışmaya özgü veriseti ve alt grupları oluşturulmuştur. Bu veri setleri: Omurilik Aksiyel GM/BM (Global) (Şekil 4.2(a)), Omurilik Aksiyel OKA/BOS (Özgün) (Şekil 4.2(b)), Omurilik Aksiyel MS (Özgün) (Şekil 4.2(d)), Omurilik Sagittal MS (Özgün) (Şekil 4.2(e)) şeklinde isimlendirilmiştir. Şekil 4.2'de açık veriseti ve özgün verisetinden ITK-SNAP yazılım aracı (Yushkevich vd., 2006: 1116) orijinal MR kesiti ve hazırlanan maske verileri ile birlikte çalışılan hedef alan gösterilmektedir.



Şekil 4.2. Veri setlerinde bulunan MR görüntüsü, MR görüntüsüne ait işaretlenmiş maske görüntüleri ve ilgili alanın işaretlenmesi (a) omurilik GM/BM aksiyel T2a MR, (b) omurilik OKA/BOS aksiyel T2a MR, (c) omurilik MS aksiyel T2a MR, (d) omurilik MS sagittal T2a MR

4.1.1. Global Veriseti (SCGMSC)

Tez çalışmasında, literatürde omurilik çalışmalarında kullanılan global bir veriseti olan “Spinal cord grey matter segmentation challenge (SCGMSC)” veriseti kullanılarak omurilik gri ve beyaz bölge otomatik olarak bölütlenerek, elde edilen sonuçlar önerilen mimarilerin sonuçları ile karşılaştırılmıştır. SCGMSC veriseti (Ferran Prados vd., 2017:


312), University College of London, Ecole Polytechnique de Montreal, University of Zurich ve Vanderbilt University isimli dört üniversitenin eğitim amaçlı kullanım için hazırlamış olduğu bir verisetidir. “Gray matter spinal cord bölütleme yarışması” kapsamında veriler herkese açık halde sunulmuş olup talep edilmesi halinde iletilmektedir.

Tablo 4.1. SCGMSC açık kaynak veriseti içerik bilgileri (K:Kadın, E:Erkek)

	Veri Merkezleri			
	Site 1-UCL	Site 2-Montreal	Site 3-Zurich	Site 4-Vanderbilt
Veri sayısı (eğitim, test)	20 (10,10)	20 (10,10)	20 (10,10)	20 (10,10)
Hasta sayısı (cinsiyete göre)	14K, 6E	11K, 9E	6K, 14E	7K, 13E
Ortalama yaş (standart sapma)	44.3 (10.4)	33.7 (17.4)	40.6 (10.4)	28.3 (8.2)
Veri Edinimi ve Tarayıcı Teknik Bilgileri				
Tarayıcı	3 T Philips Achieva	3 T Siemens TIM Trio	3 T Siemens Skyra	3 T Philips Achieva
Sekans	3B Gradient echo	2D spoiled gradient multi-echo	3B multi-echo gradient-echo	3B multi-echo gradient-echo
Maske	40 (4 farklı uzman)	40 (4 farklı uzman)	40 (4 farklı uzman)	40 (4 farklı uzman)
Toplam MR görüntüsü	30 (kesit)	113(kesit)	178(kesit)	133(kesit)
Toplam maske görüntüsü	30(kesit)	113(kesit)	149(kesit)	132(kesit)
TE (ms)	5	5.41,12.56,19.16	19	7.2,16.1,25
TR (ms)	23	539	44	700
Flip Açısı (derece)	7	35	11	28
FOV (mm)	240×180	320×320	162×192	160×160
Çözünürlük (mm)	0.5×0.5×5	0.5×0.5×5	0.25×0.25×2.5	0.3×0.3×5
NEX	8	1	5	2
Kesit	10 (3çıkarılmış)	10	20	14
Süre (d:s)	13:34	4:38	10:40	5:46
Bobin (kanallar)	16	12 + 4	16	16
Bobin tipi	Neurovascular	Head+Neck	Neurovascular	Neurovascular
Hızlandırma	–	GRAPPA factor 2	–	SENSE RL=2

SCGMSC verisetinde, Tablo 4.1.’de verilen veriler sağlıklı deneklerin omurilik bölgesinden anatomik görüntülerinden elde edilmiştir. Veriler dört farklı siteden herbirinden 10 adet test ve 10 adet eğitim veriseti temin edilmiştir. Toplam veriseti 40 adet test 40 adet eğitim olmak üzere 80 adettir. Her bir eğitim verisi için 4 farklı uzmanın manuel olarak belirlediği gri bölge maskesi bulunmakta olup test veri seti için maske verisi bulunmaktadır. Teknik detayları incelenecek olursa veriler 4 farklı makineden çekim alındığı için her bir MR verisinin içerdiği kesit sayısı ve özellikleri boyutları

farklılık göstermektedir. Verisetinde MR görüntüleri farklı marka 3T makineler ile elde edilmiştir. Bu nedenle MR verilerinin sahip olduğu teknik detaylar farklılık göstermektedir. Bu verilere ait her bir veri sağlayıcısı için verilen omurilik MR görüntüsü ve MR görüntüsüne ait 4 farklı uzman tarafından işaretlemesi yapılmıştır. Bu nedenle deneysel çalışmalar süresince 4 nolu maske verisi kullanılmıştır. Bu inceleme sonucu SCGMSC verisetinden her bir veri sağlayıcısından örnek bir MR görüntü ve uzman tarafından etiketlenen maske verisi Şekil 4.3.'te verilmiştir.



Şekil 4.3. SCGMSC verisetinde her bir veri sağlayıcısı için kullanılan MR verileri ve MR görüntüsüne ait maske verileri. (a, c) MR kesiti, (b, d) uzman tarafından etiketlenmiş maske

SCGMSC verisetinde, farklı boyutlara sahip olan MR verileri nedeniyle bazı ön işleme işlemlerinden geçirilerek veri seti 128x128 .png formatında tek bir boyutta olacak şekilde yeniden düzenlenmiştir. Veriler görüntü ve o görüntülere ait maskelerden oluşan eşit boyutlarda yeni bir veri seti oluşturulmuştur. Boyut farklılığı U-Net mimarisinde eğitim yapılabilmesi için bir engel oluşturmaktadır ve bu nedenle tüm görüntüleri bir ön işleme tabi tutarak görüntü ve maske boyutlarını eşitlenmesi gerekmektedir. Tüm ön işleme prosedürleri, Python ortamında omurilik MR görüntüleri için maske merkezleri kullanılarak gerçekleştirilmiştir.

4.1.2. Servikal Omurilik MR Veriseti



Tez çalışmasında, Omurilik bölgesinin bölütlenmesi ve omurilik MS lezyonlarının tespit edilmesi çalışması kapsamında gerekli olan MR verilerinin temini Akdeniz Üniversitesi Hastanesinden temin edilmiş olup çalışmanın yürütülmesinde bir sakınca

olmadığı Akdeniz Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulunun 15.09.2021 tarihli KAEK-644 nolu kararı ile onaylanmıştır. Çalışma kapsamında görüntüler medikal veri görüntüleme formatı olarak kullanılan DICOM formatı ile temin edilmiştir. Bu bağlamda, Akdeniz Üniversitesi Hastanesindeki kimlik bilgileri, cinsiyeti, yaşı gibi özelliklerinden bağımsız olarak temin edilen omurilik bölgesine ait turbo spin echo sekansında T2a servikal omurilik MR verileri temin edilerek çalışmaların kapsamına özgü bir etiketleme işlemleri yapılarak alt grup verisetleri oluşturulmuştur.

DICOM formatında temin edilen servikal omurilik MR verileri içerisinde klinik uzmanların talepleri doğrultusunda aksiyel, sagittal ve koronal vb. farklı çekimler bulunmaktadır. Servikal omurilik bölgesinin bütüncül bir yaklaşımla bölütme çalışmaları gerçekleştirmek amacıyla aksiyel ve sagittal MR verileri kullanılarak bölütlenmesi hedeflenen alanların ayrı ayrı maskeleme işlemleri yapılarak alt veri grupları oluşturulmuştur. Aksiyel çekimler kullanılarak omurilik alanı (OKA) ve beyin omurilik sıvısı alanı (BOS) işaretlemeleri yapılarak omurilik aksiyel OKA/BOS veri alt grubu oluşturulmuştur. Yine servikal omurilik MR verileri içerisinde aksiyel ve sagittal verilerde omurilik ve MS lezyon alanlarının işaretlenmesi yapılarak omurilik aksiyel MS ve omurilik sagittal MS veri alt grupları oluşturulmuştur. Servikal omurilik MR verileri ile toplam üç adet birbirinden farklı ve özgün veri seti alt grupları hazırlanmıştır.

Çalışmada kullanabilecek çekim kalitesine sahip olan veriler tek tek incelenerek her bir servikal omurilik MR verisi ITK-SNAP yazılım aracı (Yushkevich vd., 2006: 1116) kullanılarak NifTI formatında yeniden kaydedilmiştir. Veriler T2 sekansı kullanılarak çekilen servikal omurilik MR görüntülerinden oluşmaktadır. MR verilerinde çalışılmak istenilen omurilik alanları ve omurilik içerisinde bulunan MS lezyonları tek tek işaretlenerek uzman maske verileri oluşturulmuştur. Radyoloji alanında iki farklı uzman tarafından onaylanan maske verileri de NifTI formatında kaydedilerek MR görüntüsü ve maskelerinden oluşan özgün verisetleri elde edilmiştir. Çalışmalarda kullanılabilecek MR kesitlerinin sayısı MR çekim esnasında kullanılan parametrelere bağlı olarak farklı adetlerce elde edilmiştir. Model eğitimi için yetersiz olması halinde veri kümeleri için veri artırma işlemi yapılarak veri sayısında iyileştirme işlemleri yapılmıştır.

Tablo 4.2. Omurilik aksiyel OKA/BOS, omurilik aksiyel MS ve omurilik sagittal MS alt gruplarından oluşan servikal omurilik MR veriseti teknik bilgileri ve parametreleri


	Omurilik Aksiyel OKA/BOS	Omurilik Aksiyel MS	Omurilik Sagittal MS
			
Hasta sayısı	87	87	87
Kullanılan BT tarama sayısı	20	87	50
Hastanın yaş aralığı	18-72	18-72	18-72
MR makinesi	SIEMENS Spectra Magnetom	SIEMENS Spectra Magnetom	SIEMENS Spectra Magnetom
Tarama modu	2D	2D	2D
Seri açıklaması	T2_TSE_TRA	T2_TSE_TRA	T2_TSE_SAG
Modalite	Transversal T2-a	Transversal T2-a	Sagittal T2-a
Manyetik güç (T)	3.0	3.0	3.0
Kesit kalınlığı (mm)	4	4	3
Tekrarlama süresi (ms)	3420	3420	3000
Yankı süresi (ms)	86	86	97
Görüntüleme sıklığı	123.185655	123.185655	123.185655
Kesitler arasındaki boşluk	5.2	5.2	3.3
Örnekleme yüzdesi	90	90	70
Görüntü alanının yüzde fazı	78.125	78.125	100
Piksel bant genişliği	260	260	260
Döndürme açısı (FA)	150	150	150
Boyutlar (piksel)	320x250	320x250	320x320 384x324 384x348 384x384
Dilim sayısı	24-30	24-30	13-15
Ny, NEX	239, 3.00	239, 3.00	239, 3.00
Voksel aralığı	0.6875x0.6875x5.2	0.6875x0.6875x5.2	0.572917x0.572917x3.3 0.625x0.625x3.3 0.78125x0.78125x3.3

Alt gruplarda, ilk olarak aksiyel çekimler kullanılarak OKA ve BOS alanı işaretlemeleri yapılarak omurilik aksiyel OKA/BOS veri alt grubu oluşturulmuştur. OKA/BOS bölütlemesi için verisetindeki toplam 87 hastadan temin edilen servikal omurilik MR taramalarından 20 adet MR taraması kullanılmıştır. İkinci olarak, servikal omurilik bölgesinin ve omurilik bölgesi içerisinde mevcut olan MS lezyonlarını inceleyebilmek için servikal omurilik bölgesi T2a MR verileriAksiyel düzlemdeki alt gruplarda ortalama 24 ile 30 arasında kesit olup, taramalardaki kesit kalınlığı 4 mm'dir. MR taramalarında tekraralama süresi (TR, repetition time) 3420.00 ms ile 3970.00 ms arasında değişmekte olup, yankı süresi (TE, echo time) ise 86.00 ms'dir. Hasta taramalarında diğer çekim parametreleri ise, ETL=17


k-space, $N_y=239$, $NEX=3.00$ ve $FA=150.00$ deg şeklindedir. Son olarak sagittal kesitte MS lezyonlarının incelenmesi için servikal omurilik bölgesi T2a MR verileri ile diğer bir veriseti alt grubu oluşturulmuştur. Veriler klinikte MS teşhisi almış 50 hastanın MR taramasına ait olup yaş ve cinsiyet gibi kişisel özelliklerden bağımsız olarak elde edilmiştir. Her bir hasta için omuriliğin yaklaşık C1-C7 aksına denk gelen T2a MR taramaları 13-15 arasında MR kesiti bulunmaktadır. Sagittal omurilik MR verileri 320x320, 384x324, 384x348, 384x384 farklı piksel boyutlarında değişmektedir. Üç farklı alt grup içeren servikal omurilik verisetinin teknik bilgileri ve edinim parametreleri Tablo 4.2.'de detaylı olarak verilmiştir.

4.1.3. Veri Etiketleme ve Ön-İşleme

MR görüntülerinin ITK-SNAP ortamında etiketleme işlemi için örnek bir gösterimi Şekil 4.4.'te verilmiştir. Öncelikle, DICOM formatındaki orijinal MR görüntüleri ve hazırlanan maskeleri NifTI formatında yeniden kaydedilmiştir. Şekil 4.4.'ten görüldüğü üzere çalışılmak istenilen ilgili bölge (ROI, region of interest) genel MR verisinde oldukça küçük bir yer kaplamaktadır. Deneysel çalışmalar esnasında gereksiz arka planların dez avantajlarını elimine etmek ve model başarısını arttırmak için kırpma işlemi uygulanmıştır. Yapılan uygulama ile görüntüler tek boyutta indirgenerek yeniden boyutlandırma işlemleri yapılmıştır. Bu işlem maske merkezleri baz alınarak 128x128 ölçüsüne göre kırpma işlemi uygulanmıştır. Tüm işlemlerin sonunda veriseti için 500 tane png formatında T2a MR görüntü elde edilmiştir. Ayrıca veri artırma tekniği uygulanarak toplam 1000 adet png MR verisi ve bunların uzman maskelerini içeren veriseti hazırlanmıştır. Ön işleme aşamasından geçen verisetinden örnek MR görüntüleri ve maskeleri Şekil 4.5.'te verilmiştir.




Şekil 4.4. Omurilik aksiyel OKA/BOS T2a MR verileri ve MR görüntüsüne ait işaretlenmiş maske verilerinin görüntüleri



Şekil 4.5. Omurilik aksiyel OKA/BOS T2a MR verileri 128x128 olarak yeniden boyutlandırılmış örnek görselleri


Şekil 4.6’da servikal omurilik sınırları içerisinde bu alana karşılık gelen aksiyel kesitlerde omurilik ve beyin omurilik sıvısı alanlarının şekil, biçim ve yoğunluk bakımından farklılıklar olduğu görülmektedir. Bu farklılık verisetini kendi içerisinde özelleşmesine önemli ölçüde katkı sunmakta olup bu sayede görüntü çeşitliliği sağlamaktadır.



Şekil 4.6. Servikal omuriliğin sagittal ve aksiyel kesit OKA/BOS T2a MR görüntüsü ve MR görüntüsünün maske verileri


Şekil 4.7’de servikal omurilik MR verileri kullanılarak omurilik sınırları içerisinde bu alana karşılık gelen aksiyel kesitler tek tek incelenerek öncelikle MS lezyonları tespit edilmiştir. Servikal omurilik boyunca tüm kesitlerde MS lezyonu olmadığı için etiketleme

işlemi tüm kesitler yerine sadece MS olan kesitlerde yapılmıştır. Bu sebeple elde edilen toplam görüntü sayısı oldukça azalmaktadır. Fakat yine her bir omurilik kesitinin ve MS lezyonlarının birbirinden benzersiz olması verisetini kendi içerisinde özelleşmesine önemli ölçüde katkı sunmaktadır.




Şekil 4.7. Servikal Omurilik MS Aksiyel T2a MR görüntüsü ve MR görüntüsünde MS lezyonun konumu

Servikal omurilik MS alr grubunda tüm işlemlerin sonunda 87 adet MR görüntüsünden 231 tane png formatında MS lezyonu barındıran kesit elde edilmiştir. MR verilerinin içerdiği kesit sayısı 24 ile 30 arasında değişkenlik gösterdiği düşünüldüğünde MS lezyonu içeren kesit sayısının yaklaşık ortalama 3 olduğu görülmektedir. Bu nedenle veri sayısı oldukça düşük sayılarda kalmıştır. Veri artırma tekniği uygulanarak toplam 1080 adet png MR verisi ve bu MR verilerinin uzman maskelerini içeren veriseti hazırlanmıştır. MS lezyonu içeren ve ön işleme aşamasından geçen verisetinden örnek MR görüntüleri ve maskeleri Şekil 4.8’de verilmiştir.



Şekil 4.8. Servikal Omurilik MS Aksiyel T2a MR verileri 128x128 olarak yeniden boyutlandırılmış örnek görseller




Şekil 4.9. Servikal Omurilik MS Sagital T2a MR görüntüsü ve MR görüntüsünün maskeleri


Sagital omurilik MR görüntülerde MS lezyonları sıklıkla puro şeklinde/silindirik, aksiyel görüntülerde ise kama şeklinde görünür ve tipik olarak keskin sınırlara sahiptir (Filippi vd., 2019: 1858). Sagital görünümünde uzunlukları nadiren iki vertebral segmenti aşmaktadır. Şekil 4.9’da servikal omurilik sınırları içerisinde bu alana karşılık gelen sagittal kesitlerde MS içeren kesitler tek tek incelenerek tespit edilmiştir. Servikal omurilik boyunca tüm kesitlerde MS lezyonu olmadığı için etiketleme işlemi tüm kesitler yerine sadece MS

olan kesitlerde yapılmıştır. Temin edilen MR verileri ortalama 13 kesit içermekte ve bu kesitlerde tüm omurilik bölgesi 2 veya 3 kesitte izlenebilirken MS lezyonları ortalaması 1 veya 2 kesit kadar olmaktadır. Bu durum veri sayısını oldukça düşürmekte olduğundan elde edilen toplam 80 adet kesit için veri arttırma işlemleri yapılarak veri sayısında iyileştirme yapılmıştır.

Servikal Omurilik MS Sagittal alt veri grubu için ITK-SNAP yazılımı kullanılarak yapılmış olan örnek bir etiketleme çalışması Şekil 4.10'da verilmektedir. Öncelikle, DICOM formatındaki orijinal MR görüntüleri ve hazırlanan maskeleri NifTI formatında yeniden kaydedilmiştir. Servikal omurilik MR verilerinde aksiyel planellerde çalışılan ilgili bölgeler MR görüntüsünde oldukça küçük yer kapladığı için yeniden boyutlandırma işlemleri yapılırken sagittal MR planellerinde boyut azaltma işlemleri yerine boyut eşitleme işlemleri yapılmıştır. Her ne kadar aynı makinelerde çekim yapılmış olsada teknik personel veya herhangi farklı durumlar nedeniyle sagittal MR verilerinde boyut farklılıkları olan MR verilerinin olduğu tespit edilmiştir. Bu nedenle 320x320 olarak yeniden boyutlandırma işlemleri yapılmıştır. Ön işleme aşamasından boyut eşitleme işlemlerinden sonra verisetinden örnek MR görüntüleri ve uzman maskeleri Şekil 4.11'de verilmiştir.



Şekil 4.10. Servikal Omurilik MS Sagittal T2a MR verileri ve MR görüntüsüne ait işaretlenmiş maske verilerinin görüntüleri



Şekil 4.11. Servikal Omurilik MS Sagittal T2a MR verileri 320x320 olarak yeniden boyutlandırılmış örnek görseller

4.2. Veri Artırma

Veri artırma (data augmentation), makine öğrenimi ve derin öğrenme modellerinin performansını artırmak için kullanılan önemli bir tekniktir. Veri artırma, veri setlerinin kalitesini ve çeşitliliğini artırarak, modelin daha doğru, dayanıklı ve genelleştirilebilir hale gelmesini sağlar. Veri setinin yetersizliği, modelin genelleme yeteneğini artırma, daha dengeli bir veri seti oluşturma, modelin dayanıklılığını artırma, veri anomalisinin azaltılması, modelin performansını ve verimliliğini artırma gibi teknik gerekçeler için veri artırma işlemleri makine öğrenimi derin öğrenme ve alt dallarında sıklıkla tercih edilen bir yöntemdir. Özellikle veri toplama ve derleme işlemlerinin çok zahmetli ve pahalı olması biyomedikal alanda veri artırma yöntemleri oldukça kritik bir durum olmaktadır. Genellikle amaç elde edilen mevcut veri setini çeşitli yöntemler kullanarak yapay bir şekilde genişletmek ve modelin performansını olumlu yönde etkilemektir. Bu teknik sayesinde veri eksikliği, modelin genelleme yeteneği, sınıf dengesizliği gibi birçok sorun elimine edilerek daha güçlü ve dayanıklı modellerin geliştirilmesine olanak tanınmaktadır. Fakat kullanılacak olan veri artırma tekniklerinin doğru bir şekilde değerlendirilerek en güvenli yol ve yöntem tercih edilmelidir.

Medikal görüntüler için genellikle döndürme (rotation), çevirme (flipping), ölçekleme (scaling), kırpma (cropping), parlaklık değişimi (brightness adjustment) ve gürültü eklemek (adding noise) gibi teknikler sıklıkla veri artırma için kullanılmaktadır (Kusrini vd., 2020: 105842). Medikal kesitler üzerinde yapılan döndürme işlemi ile modelin farklı perspektiflerden mevcut veriyi tanıması sağlanırken çevirme işlemleri yatay dikey konumlar için belirli oranlarda verinin bütünlüğünü kaybetmeyecek şekilde yapılabilmektedir. Genellikle sağ veya sol perspektiflik durumun önemli olmadığı MR ve diğer görüntüleme tekniklerinde yeni veriler elde edilmesi için sıklıkla kullanılmaktadır.

Diğer önemli bir teknik ise ölçekleme yöntemleridir. Bu yöntem ile çalışılması küçük alanlar için boyut küçültme veya tam tersi durumlar için büyütme işlemleri ile boyut değiştirmek mümkün hale gelmektedir. Özellikle gereksiz arka plana sahip olan MR verilerinde çalışılmak istenilen ilgili bölgelerin daha net ortaya çıkması için ve eğitim süresine olumlu katkı sunmak için kırpma işlemleri gerekli olmaktadır.

Tez çalışması kapsamında kullanılan U-Net modellerinin genel başarısına olumlu katkı sunacak en önemli adımlardan birisi veri artırma işlemleridir. Bu çalışmada, veri çoğaltılması için NumPy kütüphanesinin döndürme (x ve y eksenlerinde), çevirme, kaydırma ve aynı işlevleri kullanılmıştır. Omurilik bölgesinin farklı şekil yapılarına sahip olması MS lezyonlarının birbirinden benzersiz konum ve boyutlarda oluşu temel verisiteinde çeşitliliği sağlayan en önemli faktördür. Buna ek olarak yapılan veri artırma işlemleri ile veri seti hazır hale getirilerek model eğitimlerinde sırası ile kullanılmıştır.

4.3. Metodoloji

Yapay zeka ve makine öğrenmesi gibi araştırma konularının literatürlere girmesi ile birlikte birçok alt araştırma konuları doğmuştur. Bunlardan en popüler olanı ise yapay sinir ağlarının gelişim süreci ile birlikte evrişim sinir ağlarının daha derin ağ modeller geliştirme fikri ile geliştirilen derin öğrenme mimarileridir. 1943’de W. McCulloch ve W.Pitts tarafından önerilen ilk yapay sinir ağı modeli insan beyninin hesaplama özelliği kullanılarak basit bir sinir ağı modeli geliştirmişlerdir (Krizhevsky vd., 2012).


Temelde insan sinir sisteminden ilham alınarak geliştirilen yapay sinir ağları günlük hayatımızda ses asistanları, öneri sistemleri, görüntü işleme ve bilgisayarla görme, sağlık ve medikal tanı amaçlı, otonom araçlar, finans sektörü, eğlence ve oyun alanlarında ve akıllı ev cihazları olarak karşımıza çıkmaktadır. İnsan beyni ölçeğince karar verebilen mimariler geliştirilirken başarı kriteri insan yetenekleri çerçevesince değerlendirilmektedir. Şöyle ki insan düzeyine yakın nesne tanınması, konuşmaları sınıflandırması, metin okuma ve belki seslendirme yapabilmesi tasarlanan sistemin başarısını göstermektedir. Gelişimin ve çalışmanın çok hızlı olduğu bir alan olmakla birlikte birçok farklı disiplinle alanlarla da içiçe çalışmalar yapılmaktadır.

4.3.1. Derin Öğrenme

Yapay sinir ağları birkaç katmanlı yapılar olarak tasarlanırken derin sinir ağlar ile çok katmanlı yapıların kullanılması modelin ne kadar derin olduğunu belirlemektedir. İki önemli gelişme ile derin öğrenme alanı bir sıçrama yaşamıştır. Birincisi ImageNet yarışması ile elde edilen nesne sınıflandırma konusunda elde edilen başarısıdır. İkincisi

ise merkezi işleme birimleri olan CPU'ların yerini grafik işleme birimlerine kısaca GPU'larına bırakması diğer etkindir. Donanımsal olarak yetersizliğin giderilmesi ile birlikte derin öğrenme modellerinin katman sayısı artırılarak daha derin yeni mimarinin tasarlanması hız kazanmıştır. Derin ağların geliştirilmesi için birçok farklı sinir ağı geliştirilmiştir. Bunlardan en çok kullanılanlarından bazıları Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN), Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNN), Uzun Kısa Dönemli Bellek (Long / Short Term Memory, LSTM), Derin İnanç Ağları (Deep Belief Networks, DBN), Çekişmeli Üretici Ağlar (Generative Adversarial Networks, GAN) gibi örnekler verilebilmektedir. Fakat derin öğrenme mimarilerinde en çok kullanılan ve temel yapısı kullanılarak model CNN'dir.

Derin öğrenme mimarilerinde GPU teknolojisi ve büyük veri kümelerinin kullanıma sunulması ile birlikte görüntü sınıflandırma, sınıflandırma ve lokalisasyon ve algılama konu başlıkları altında nesne tanıma ve takip etme, doğal dil işlemede anlam ayırttırma, cümle modelleme, tahmin problemleri gibi birçok alanda birbirinden farklı CNN mimarileri geliştirilmiştir (Gu vd., 2018: 354; LeCun vd., 2015: 436). CNN'nin öncül katmanlarında kenar bilgisi gibi daha ilkel öznitelikler elde edilirken, derin katmanlarda görüntüyü temsil eden karmaşık öznitelikler elde edilmektedir. Şekil 4.12'de görüldüğü gibi CNN mimarisi; evrişim katmanı, ortaklama katmanı ve tam bağlantılı katmanı olmak üzere üç ana katmanla ifade ederken bazıları giriş katmanı, batch normalizasyon katmanı, aktivasyon katmanı, dropout katmanı ve sınıflandırma katmanlarını da evrişim yapısına dahil etmektedirler (Sakib vd., 2019). Evrişim ağlar genel anlamıyla özellik çıkarımı, havuzlama, sınıflandırma ve tanıma işlemlerini gerçekleştiren her bir katmanında ayrı bir matematiksel işlem yürütülen bir modellemedir (Yamashita vd., 2018: 611). Temelde her bir katmanda giriş görüntüsünden itibaren filtreler yardımıyla geri yayılım ile güncellenen ağırlıklar matrisinin sonucuna göre hedef çıktılara ulaşılması durumu olarak ifade edilebilmektedir.



Şekil 4.12. Evrişim sinir ağı model aşamaları

Giriş katmanı, bu katman isminden de anlaşılacağı üzere evrişim ağının ilk katmanını oluşturmaktadır. Bu katmanda çalışılacak olan veri seti ham olarak modele giriş verisi olarak sunulmaktadır. Evrişim katmanı, giriş katmanının devamında

özniteliklerin çıkarıldığı matematiksel işlemleri içeren evrişim katmanı ile devam etmektedir. Giriş verisinin sahip olduğu her bir pikselin sayısal değerleri vardır. Bu sayısal değerler filtre, kernel veya maske olarak ifade edilen 3x3, 5x5 vb. gibi boyutlu matrislerin görüntü verisinin ilk satır ve sütun pikselinden başlayarak gezdirilmektedir (Xiangyu Zhang vd., 2015: 1943). Bu gezdirilme esnasında filtreler de denk gelen sayısal her bir değer evrişim işlemine tabi tutulmaktadır. Bu işlem kısaca bir çarpma işlemi uygulaması olup bu çarpma işleminden elde edilen sonuçlar toplanarak yeni ve tek bir sayısal değer elde edilmektedir. Elde edilen her bir sonuç matriste yerine yazılarak yeni bir veri kümesi olarak kaydedilmektedir. Bu işlem ile veri kümesi değişmekte olup farklı özelliklere sahip öznitelik haritaları (feature map) elde edilebilmektedir (Gu vd., 2018: 354). Bu nedenle bunların her biri ağı oluştururken dikkat edilmesi gereken parametre değerleri olarak özenle seçilmelidir.

Derin öğrenmede, toplu normalleştirme katmanı (batch normalization layer), ön işlem tekniği olarak kullanılarak batch işlemi, verilerin standartlaştırmak için kullanılmaktadır (Ioffe, 2015). Eğitim aşamasında modelin eğitim süresini hızlandırarak daha yüksek başarı skorları elde etmeyi sağlamaktadır. Genel kullanım yeri ise evrişim ile aktivasyon fonksiyonu arasında tercih edilmektedir. Aktivasyon katmanı (activation layer), basit bir lineer regresyon modelinden daha karmaşık olan verileri ağı öğrenbilmesini için doğrusal olmayan dönüşümler sağlayan yapı aktivasyon fonksiyonlarıdır (Goodfellow, 2016). ReLu, tanh, sigmoid gibi aktivasyon fonksiyonları sıklıkla sinir ağı mimarilerinde kullanılmaktadır. Relu aktivasyon fonksiyonu çalışmalarda sıklıkla kullanılmakta olup tez çalışması kapsamınca da ReLu aktivasyon fonksiyonu kullanılmıştır (Nair ve Hinton, 2010: 807). Hız açısından diğer aktivasyon fonksiyonlarına göre daha avantajlı olmasına rağmen probleme göre aktivasyon fonksiyonunu belirlemek en doğru yaklaşım olarak kabul görmektedir.

Ortaklama (pooling) katmanı, evrişim ağı mimarilerinin diğer önemli katmanı olup bir boyut azaltma (down sampling) işlemi olarak görev yapmakta olup herhangi bir öğrenme işlemi gerçekleşmemektedir (Wu, 2017: 495). Genel olarak ifade edilmek istenilirse, giriş matrisinin kanal sayısı sabit kalacak şekilde genişlik ve yükseklik bazında ağıdaki parametre sayısını ve hesaplama miktarını azaltmaktadır. Veride bulunan yüksek değerlikli özelliklerin korunmasına ve modelin en etkin bir şekilde eğitilmesine katkı sağlamaktadır. Ortalama ortaklama (average pooling) ve maksimum ortaklama (maximum pooling) olmak üzere iki şekilde yapılabilmesine karşılık en çok maksimum ortaklama tercih edilmektedir (He vd., 2016: 770).

Tam bağlantı & düzleştirme (flattening) katmanı, evrişim ve havuzlama işlemlerinin sonucunda elde edilen son tensör kümesini tek boyutlu vektöre dönüştürmek için yapılmaktadır (Yamashita vd., 2018: 611). Sınıflandırma işlemlerinin gerçekleşmesi için yapay sinir ağ modeline verilecek olan matrisin tek boyuta indirgenmiş olması gerekmektedir. Bu nedenle düzleştirici (flatten) ve tam bağlantılı katmanlara ihtiyaç duyulmaktadır. Seyreltme (dropout-bırakma) katmanı, model eğitimlerinin son aşamasında bazı nöronların göz ardı edilerek model eğitiminde aşırı öğrenme (overfitting) durumu var ise kullanılması modelin performansını olumlu etkileyecek bir özelliktir (Gu vd., 2018: 354; Hinton, 2012) .

Sınıflandırma katmanı, sınıflandırılmak istenilen nesne sayısı kadar çıkış değeri belirleyerek sigmoid ve softmax gibi sınıflandırıcılar kullanılarak hedef çıktılar için başarımlar hesaplanmaktadır (Yamashita vd., 2018: 611). Genel anlamda eğer iki sınıflı bir problem için sonuç üreten bir ağ yapısı ise sigmoid kullanılırken, çok sınıflı sonuç üreten bir ağ için softmax aktivasyon fonksiyonu kullanılmaktadır. Tüm ağ katmanlarının bu işlemlerin hepsini tek bir görüntü için sırasıyla yapmaktadır. Evrişim ağın sınıflandırıcı işlemi sonucunda toplam bir olacak şekilde nesne adedince skarlama işlemi yapılmaktadır.


4.3.2. U-Net Mimarisi

U-Net ise bir tür evrişimli sinir ağı temelli derin öğrenme yaklaşımıdır ve ilk olarak biyomedikal görüntüler üzerinde daha iyi bir bölütleme (bölütleme) yapma önerisi ile 2015 yılında, Olaf Ronneberger, Phillip Fischer ve Thomas Brox tarafından “U-Net: Convolutional Networks for Biomedical Image Segmentation” makalesinde duyurulmuştur(Ronneberger vd., 2015: 234). U-Net ilk olarak 2015 yılında Uluslararası Biyomedikal Görüntüleme Sempozyumu (UBGS) çok az görüntü kümesi kullanılarak eğitim yapılabildiğini ve daha önce yapılmış olan sinirsel yapıların elektron mikroskopik yığınlarda bölütlemesi çalışmalarından (Ciresan vd., 2012) daha iyi performans göstererek büyük bir farkla yarışmayı kazanmıştır. Çalışmada özetle Ronneberger vd., elektron ve ışık mikroskobu kaynağı ile elde edilmiş olan 512x512 boyutlarındaki görüntülerden oluşan veri seti ile Caffe kütüphanesi içeriğinde bulunan verisetleri ile toplam 3 farklı veri seti kullanarak bölütleme çalışması yapmışlardır. Verisetlerinde içerik olarak 30 adet elektron mikroskobu, 35 ve 20 adet ışık mikroskobu görüntüsünden oluşmaktadır. Yarışmada birinci verisetinde 0.0003529 çözümlü hatası (warping error), ikinci veri setinde %92 IoU, üçüncü veri setinde ise %77.5 IoU ile oldukça yüksek bir başarı elde edilmiştir (Ronneberger vd., 2015: 234). Elde edilen bu başarı değeri

sayesinde U-Net mimarisi oldukça fazla kullanılmaya ve araştırılmaya başlanmıştır. Son yıllarda literatürde U-Net mimarisi ve U-Net mimarisinden esinlenerek geliştirilmiş oldukça fazla mimari ve akademik çalışma vardır.

Klasik evrişimli sinir ağı modellerinde başarılı sonuç elde edilmesi ile verisetinin büyüklüğü arasında bir doğru mevcuttur. Çünkü verisetlerindeki görüntüler etiketlenerek ve özellik haritaları çıkarılarak modele verilir ve model bu verileri etiket bilgisinden tanımlayarak işlem yapmaktadır. U-Net ise diğer derin öğrenme modellerinin aksine bağlama dayalı öğrenme özelliği sayesinde daha az veri seti ile daha hızlı sonuçlar elde edilebilmektedir(Siddique vd., 2020: 1118).

U-Net mimarisi ismini Şekil 4.13.'te görüldüğü gibi mevcut U şeklinden almaktadır. Temelde evrişim ağı modellerinde bulunan yapılar ile temsil edilirken farklılaştığı özelliklerde mevcuttur. Klasik evrişim blok yapısı yine korunarak evrişim katmanı, aktivasyon katmanı ve havuzlama katmanı U-Net mimarisinin kodlayıcı (encoder) blok yapısını oluşturmaktadır. Kodlayıcı blokların karşı simetrisinde kod çözücü blok yapıları ile tersine evrişim işlemi uygulanmaktadır (Rukiye Polattimur vd., 2023: 1). Her iki yapıyı birbirine bağlayan ve U-Net mimarisini diğer evrişim mimarilerinden ayıran en önemli bağlantısı birleştirme ve bağlantı kurmak için kullanılan concatenate ismi verilen bağlantı yapısı ile sağlamaktadır.



Şekil 4.13.U-Net mimarisinin temel yapısı

U-Net derin öğrenme mimarisi kodlama (encoder) ve kod çözücü (decoder) olmak üzere simetrik iki parçanın bottleneck denilen darboğaz bağlantısı ile birbirine bağlanması ile oluşmaktadır(J. Zhang vd., 2021: 107885). Temelde klasik evrişim

mimarisinde bulunan katmanların birçoğu U-Net mimarisinde de kullanılmakla beraber tam bağlantı katmanı kullanılmamaktadır. Evrişim mimarisinin yapısından farklı olarak ise kodlayıcı ve kod çözücü bloklarını birbirine bağlayan ‘concanetane’ adı verilen bağlantıya sahiptir. Encoder yapısı U-Net mimarisinin ilk bölümünde 2 kere 3x3 normal evrişim işlemi, ReLu aktivasyonu ve aşağı yönlü iletilen veri için 2x2 maksimum havuzlama işlemlerinden oluşmaktadır (LeCun vd., 2015: 436). Bu aşamada klasik U-Net mimarisinde kullanılmayan batch normalizasyon modele entegre edilebilmektedir. Batch normalizasyon ile derin sinir ağlarının (DNN'ler) eğitim sürecinde optimizasyonu en sorunsuz ölçüde tutularak modelin daha hızlı ve daha kararlı eğitimini sağlamasına yardımcı olan bir tekniktir (Bjorck vd., 2018).

U-Net mimarisinde sıklıkla konvolüzyon, batch normalizasyon ve aktivasyon olarak sıra ile işlem görmektedir. Bu işlemler sonucunda iki adet çıktı üretilmektedir. Bunlardan birincisi bir alt basamakta bulunan evrişim bloğuna girdi olarak aktarılacak üzere bağlanırken, diğer çıktı ise karşı kod çözücü bloğuna bağlam bilgisi olarak aktarılmaktadır (Milletari vd., 2016: 565). Bu özellik U-Net mimarisinin en önemli özelliğidir. Ayrıca, her alt örnekleme basamağına geçişte filtre sayısı yani özellik sayısı ikiye katlanırken görüntü boyutu da maksimum havuzlama işlemi sayesinde yarıya düşmektedir. Alt alta bu şekilde evrişim blokları halinde tekrar eden bir yapıdan oluşmaktadır. Maksimum ortaklama işlemi görüntüyü 2x2 bloklara ayırır ve bu bloklardaki maksimum pikseli alma temeli ile işlem yapmaktadır. Böylece her bloktaki derece daha önemli bilgiler korunurken daha az önemli bilgiler atılmaktadır. Sonuç olarak giriş görüntüsünden daha küçük fakat daha anlamlı bilgileri içeren özellik haritasına sahip veri kümesi ile temsil görüntü oluşturulmaktadır. Bu işlemler 5 katman boyunca devam etmektedir. Girdi boyutuna bağlı olarak bu durum değişkenlik gösterirken klasik U-Net mimarisinde görüntünün boyutları 128x128, 64x64, 32x32, 16x16 ve son olarak 8x8 piksele kadar düşmektedir. Beşinci katmanda darboğaz (bottleneck) denilen yapı ile kodlama ve kod çözücü blok birbirine bağlanmaktadır (Çiçek vd., 2016: 424). Kodlama aşaması bittiği için havuzlama işlemi kod çözücü blokta yapılmamaktadır.

Decoder yapısı, decoder katmanında görüntü adım adım genişlemeye başlamaktadır. Yukarı yönlü görüntü boyu tekrar katmanlar arasında 2 katına çıkaracak olan tersine evrişim işlemi ile model sonunda görüntü orijinal boyutuna geri ulaşmaktadır. Kodlama bloğundan gelen aynı seviyede üretilen yüksek çözünürlüklü özellik haritaları ile kod çözücü bloğunda bulunan düşük çözünürlüklü özellik haritaları

birleştirilmektedir. Bu adım, hem detay hem de bağlam bilgisini koruyarak bölütleme performansını artırmaktadır. .Bu sayede görüntülerin her pikselin hangi sınıfa ait olduğunu tahmin edebilmek için detaylı bir özellik haritası elde edilmektedir.

U-Net mimarisinde evrişim sinir ağlarının en önemli bağlantı yapısı olan tam bağlantılı katman yerine özellik vektörünü istenen sayıda sınıfa eşlemek için 1x1 evrişim uygulanmaktadır. Klasik 5 seviyeli bir U-Net mimarisinde kodlayıcı blokta 10 evrişim katmanı, darboğaz (bottleneck) blokta 2 evrişim katmanı, kod çözücü blokta 8 evrişim katmanı ve son olarak 1 adet çıkış katmanında bulunan evrişim katmanı ile toplamda 21 adet evrişim işlemi uygulanmaktadır(Alom vd., 2018: 228),(Pattanayak, 2023). Elde edilen çıktı ile her pikselin sınıfını belirleyerek en son bölütleme maskesini üretmektedir. Bu sayede 1x1 evrişim ile her bir piksel için sınıfsal olasılıklar hesaplanmaktadır ve her bir piksel için ayrı sınıflandırma yapılabilir. Bu durumda sınıf sayısına göre son katmanda softmax (çok sınıflı veri seti için) veya sigmoid (iki sınıflı veri seti için) aktivasyon fonksiyonu kullanılmaktadır. Literatürde sıklıkla kullanılan benzerlik metrikleri ile model sonuçları değerlendirilerek model başarısı elde edilmektedir.


4.4. Hibrit U-Net Modelleri

U-Net mimarisi özellikle tıbbi görüntü alanında çok başarılı sonuçlar elde ettikten sonra araştırmacıların çok yoğun ilgisini çekmiştir. Bu nedenle çok hızlı ilerleme gösteren ve çok yoğun araştırma yapılan bir alan olmakla beraber farklı alanlarda da çalışmalar gerçekleştirilmiştir. Genel yapısı itibariyle U şeklinde olması, evrişim bloklarından oluşması U-Net mimarisinin farklı modellere evrilme esnekliği sayesinde (U-şeklinde) diğer derin öğrenme modellerinin blok yapıları veya önerilen evrişim blokları kullanılarak hibrid modeller veya farklı katman bağlantısına sahip yeni U-Net tabanlı modeller geliştirilebilmektedir. Temel U-Net modelinin etkin öğrenme özelliğine ek olarak hibrid modellerin farklı katman bağlantıları ile veriyi niteleyen özellikler katman yapısı içerisinde korunarak daha farklı öznelik kümeleri elde edilebilmektedir. Bu sayede oluşturulan yeni U-Net hibrid modellerin model eğitimleri sonucunda elde edilen performans değerine olumlu katkı sunması beklenmektedir.

4.4.1. Attention (Dikkat) U-Net

Attention U-Net (Att U-Net) mimarisi U-Net mimarisine attention mekanizması entegre edilerek Şekil 4.14.'te görüldüğü üzere yeni bir yapı olarak tasarlanmıştır. Temel U-Net mimarisi oldukça başarılı performans göstermesine rağmen özellikle tıbbi görüntüleme verilerinde ihtiyaç duyulan lezyon tümör gibi küçük, sınırlı veya gizlenmiş

nesneleri tespit etmek hala zorlu olabilmektedir. Bu küçük alanların segmente edilmesi için modelin dikkatini(attention) önemli özelliklere odaklaması ve arka plan gibi gereksiz detayları görmezden gelmesi modelin performansına önemli ölçüde katkı sunmaktadır. Attention mekanizması ile verilerin belirli özellik haritalarına veya bölümlerine "dikkat", "özen", "odak", göstermesini amacıyla kullanılmaktadır (Oktay vd., 2018: 1804.03999v3). Dikkat mekanizması özellikle bölütleme görevlerinde küçük sınırlara sahip lezyon tümör doku zedelenmeleri gibi hacimleri daha iyi tespit etmek için yaygın olarak kullanılmaktadır (B. Chen vd., 2023). Dikkat mekanizması matematiksel bir skor hesaplayarak yüksek değerlikli nitelikleri belirleyerek modelin eğitim süresi boyunca yüksek skorlu alanları kullanmasını sağlamaktadır. Bu sayede hesaplama maliyetini azaltıp ağı daha iyi genelleştirmesine yardımcı olmaktadır. Attention bağlantısı U-Net modelinde bulunan kodlama ve kod çözücü blokları arasında karşılıklı bağlantı sağlayan atlama çıktısına eklenerek kod çözücü bloğuna yukarı yönlü girdi olarak verilmektedir(Oktay vd., 2018: 1804.03999v3).




Şekil 4.14. U-Net mimarisinde dikkat (attention) blok yapısı

Dikkat mekanizmasında, klasik bir U-Net modelinin ilk katmanlarından gelen zayıf özniteliklerde kod çözücü bloğuna girdi olarak aktarılmaktadır. Bu bağlantı ile U-Net modelinde öznitelik bilgisi iletilirken araya eklenen dikkat bloğu sayesinde veriden aktarılan zayıf özellikler ve alakasız bölgeler göz ardı edilerek ağı sadece çalışma

alanına yani segmente edilecek alanına odaklanması sağlanmaktadır. Verilerden ilgisiz bölgelerin hesaplamaaya dahil edilmemesi ağı toplam hesaplama parametresini azaltarak modelin daha hızlı eğitilmesini sağlamaktadır (Siddique vd., 2020: 1118). Ayrıca bu bağlantı yapısı minimum hesaplama yüküyle U-Net modeli gibi standart evrişim mimarilerine kolayca entegre edilebilirken, model duyarlılığı ve tahmin yeteneğine önemli bir artı kazandırmaktadır. Attention mimarisinde, U-Net hesaplama verimliliğini korurken, farklı veri kümeleri ve eğitim boyutlarında U-Net'in tahmin performansını tutarlı bir şekilde iyileştirdiği tespit edilmiştir (Oktay vd., 2018: 1804.03999v3).

4.4.2. Residual U-Net

Residual U-Net (Res U-Net) mimarisi yine U-Net mimarisinden türetilmiş olup Şekil 4.15.'te gösterilen “artık”, “kısayol”, “kalıntı”, “kestirme” olarak ifade edilebilecek bağlantı yapısı sayesinde almıştır. Tüm yeni mimari tasarımlarının amacı gibi residual U-Net mimarisinin daha derin ağların eğitim süreçleri kolaylaştırmak ve model başarımını yükseltmek üzerine kurgulanmıştır. Res-Net ismi verilen Residual U-Net mimarisinin çok derin sinir ağlarının eğitimi sırasında karşılaşılan "vanishing gradient" ismi verilen kaybolan gradyan sorununu çözmek için geliştirilmiş bir evrişim mimarisidir (Y. Zhang vd., 2018: 1). Residual U-Net mimarisinde evrişim blok yapısının standart U-Net evrişim blok yapısından farkı ilk katman ile son katmanın birbirine direkt bağlanması ile elde edilmiştir. Bu artık bağlantı sayesinde giriş özellik harita bilgisi çıkış evrişim katmanına eklenerek modelin daha derin katmanları etkili ve hızlı bir şekilde ilerlemesine yardımcı olması amacıyla tasarlanmıştır.



Şekil 4.15. U-Net mimarisinde artık (residual) blok yapısı

Artık (residual) evrişimde nihai çıktı özellik haritası ile giriş özellik haritasından gelen artık bağlantı toplanarak aktivasyon işlemine tabi tutulmaktadır. Bu yapı residual

evriřim bloęu olarak ifade edilmektedir. Residual baęlantı sayesinde yakınsama probleminin önüne geçerek hızlı ve kararlı öğrenme gerçekleşmektedir(He vd., 2016: 770). Artık baęlantı yapıları ile derin aę yapısı içerisinde daha hızlı ilerleyebilmektedirken, dięer taraftan modele ek hesaplama gereksinimi doğmasına neden olmaktadır. Eğitim süreçlerinde uzamalara neden olabilmektedir. Bu nedenle, daha derin yapılar tasarlanırken model düzenlemelerinin dikkatle yapılması, aşırı öğrenme gibi olası negatif durumların ortadan kaldırılmasına yardımcı olmaktadır.

4.5. Önerilen U-Net Tabanlı Derin Öğrenme Mimarileri

U-Net yapısı, klasik evriřim bloklarından oluşan U şeklindeki mimarisi sayesinde, birçok derin öğrenme modeliyle yeniden kurgulanabilecek oldukça esnek bir yapıya sahiptir. Bu nedenle literatürde U-Net model ile yapılan birçok farklı yeni model tasarımları mevcuttur. U-Net mimarisi kodlayıcı, kod çözücü, katman birleştirme baęlantısı (concatenate) ve son katmanlar olmak üzere ayrı ayrı incelenebilmektedir. Bu katmanlarda yapılan yenilikler gelişimler modele, eğitim süreçlerine olan katkısı ölççeince değerlendirilmektedir. U-Net mimarisi kullanılarak geliştirilen mimariler göz önüne alındığında literatürde atlama baęlantıları (skip connection), omurga (backbone) dizaynı (backbone design), darboęaz (bottleneck), dönüřtürücüler (transformers), zengin temsil (rich representation), olasılıksal tasarım (probabilistic design) olarak gruplanabilmektedir(Azad vd., 2024: 1).

Atlama baęlantıları, kodlama bloęunun derin, düşük çözünürlüklü evriřim katmanından elde edilen öznitelik haritalarının kod çözücü bloęun sıę, yüksek çözünürlüklü öznitelik haritaları ile birleřtirdikleri için U-Net mimarisinin önemli bir parçası olmaktadır. Bu nedenle bu baęlantı yapısına entegre edilecek farklı evriřim bloęu veya farklı atlama yapıları kullanılarak U-Net++ (Zhou vd., 2018: 3), Att U-Net ve Res U-Net gibi yeni mimariler tasarlayarak model eğitimleri sonunda oldukça farklı sonuçlar elde etmek mümkün olmaktadır. Dięer taraftan omurga yapı aslında klasik U-Net mimarisinin ikili evriřim bloklarını temsil etmektedir.

Omurga, ham veriden anlamlı öznitelikleri çıkaran katmanlar dizisi olarak ifade edilebilmektedir. Her derin mimarinin temel omurga yapısı farklı olmaktadır. Farklı özellięe sahip derin mimarilerin U-Net mimarisi blok yapısına entegre edilmesi ile residual U-Net, V-Net (Milletari vd., 2016: 565) gibi farklı mimariler elde edilebilmektedir. Mimarinin daha derin özellikli olmasına neden olan bu yapısal deęişim parametre sayılarının artışına neden olurken model başarımlarını olumlu yönde etkileyebilmektedir. Bu iki durumun iyi analiz edilerek mimari yapısına karar verilmesi

model eğitiminden elde edilecek sonuçları en optimum noktaya ulaşmasını sağlamaktadır.

Darboğaz (bottleneck) dediğimiz yapı kodlayıcı ve kod çözücü blok yapısını birbirine bağlayan U-Net mimarisinin taban evrişim yapısını oluşturmaktadır. Klasik U-Net mimarisinde tüm evrişim bloklarını yenilemek yerine bottleneck dediğimiz yapıya yeni evrişim yapıları veya diğer bağlantı yapıları kullanılarak Ma-Net (Fan vd., 2020: 179656), Sa-U-Net (Guo vd., 2021: 1236) gibi farklı U-Net modelleri tasarlamakta olası bir diğer durumdur.

Diğer taraftan, dönüştürücü tipi model geliştirme yöntemi ile TransUNet (J. Chen vd., 2021), TransBTS (Wenxuan vd., 2021: 109) gibi mimariler tasarlanmıştır. Bu tip mimarilerde kodlayıcı veya kod çözücü bloklarında yapılan farklılıklar ile attention yapılarının modele entegre edilmiştir. Zengin temsil tipi model geliştirme teknikleri mimaride mevcut olan daha zengin ve önemli özellikleri öğrenmek için kurgulanmış yapılardır. Bu sayede modelin sadece yüzeysel değil, aynı zamanda daha soyut ve yüksek seviyeli özellikleri de çıkarabilmesi sağlanmaktadır.

Zengin temsil U-Net mimarileri, klasik U-Net'in temel özellik çıkarma kapasitesini genişletmek amacıyla, çeşitli teknikler ve mimari değişiklikler kullanılarak geliştirilmiştir. Bu modellere Focal Tversky Attention U-Net (Abraham ve Khan, 2019: 683), Cascaded U-Net (Lachinov vd., 2018: 189) gibi örnek çalışmalar gösterilebilmektedir. Olasılıksal yapıların kullanılarak geliştirildiği model tasarımlarında model çıktılarına bir belirsizlik (uncertainty) metriği eklenerek, hangi bölütleme sonuçlarının güvenilir olduğunu belirlemeyi amaçlayan mimari yapılarıdır. Bu yaklaşım, özellikle tıbbi görüntülerde, modelin bazı bölgelerde daha az emin olduğu durumları tespit etmeye yardımcı olabilmektedir. Bu bağlamda geliştirilen Bayesian Skip Net (Klug vd., 2021: 168), Probabilistic U-Net (Kohl vd., 2018) gibi modeller daha detaylı incelenebilmektedir.


Tez çalışması kapsamında, tasarlanmış veya yenilik eklenmiş mimari yapılar çok detaylı olarak incelenerek farklı U-Net mimarileri geliştirilmiştir. Yukarıda anlatılan model geliştirme yöntemleri temel alınarak öncelikle omurga yapısına katkı sunacak yeni bir evrişim yapısının tasarlanmıştır. Bu kapsamda evrişim mimari yapılarında biri olan fraktal (fractal) evrişim modeli yapısının U-Net mimarisine entegre edilmesi gerçekleştirilmiştir. Ayrıca, klasik U-Net mimarisinde direkt bağlantı ile birleştirme işlemi yapılırken fractal evrişim blok yapısı bağlantıya entegre edilmesi ile ikinci bir

mimari daha geliştirilmiştir. Son olarak artık mekanizmasının U-Net modellerine entegre edilmesi işlemi fraktal yapısı ile birleştirilerek yeni bir U-Net mimarisi daha önerilmiştir.

4.5.1. FractalSpiNet

Tez kapsamında, U-Net mimarisi tabanlı geliştirilen ilk model FractalSpiNet mimarisidir. Bu mimari için evrişim blok yapısına yeni bir bakış sunan (Larsson vd., 2016) çalışmasından ilham alınmıştır. FractalSpiNet mimarisinin temelinde, U-Net mimarisinde kullanılan ResNet evrişim blok yapısının, Şekil 4.16.'da gösterilen fraktal yapısı ile değiştirilmesi yatmaktadır.

Derin sinir ağlarından da bildiğimiz gibi ağın performansını olumsuz etkileyerek aşırı öğrenme (overfitting) gibi durumların yaşanmasına sebep olabilmektedir. ResNet gibi derin ağların optimizasyonu kolaylaştırmak için atlamalı bağlantılar kullanılabilir. Fakat bu durumlar ağın karmaşık yapısını daha da artırması muhtemeldir. Fraktal evrişim modelinin ResNet'den farklı olarak geçişli ve artık sinyallerin iletilme şekli bağlantısal olarak birbirinden ayrıdır. Çünkü ResNet bu iki bağlantı için ayrıcalık tanırken fraktal hiçbir sinyal için öncelikli olma durumu yoktur. Fraktal mimarisinde, birleştirme katmanına yapılan her giriş bir önceki evrişim çıkışının çıktısı şeklindedir. Ağ yapısı tek başına herhangi birini birincil olarak tanımlamamasına karşılık öncelikli bağlantı yapıları kullanılarak farklı evrişim bağlantısına sahip mimariler geliştirmek mümkündür.



Şekil 4.16. Fractal evrişim blok yapısı

En temelinde Mandelbrot fraktal geometriyi fraktal bir boyutsallık ile temsil eden istatistiksel bir nicelik olarak ifade etmektedir. Yani fraktal, kendi içerisinde benzer olan yani öz benzerliğe sahip şekiller dizisinin bir bütünü oluşturması sonucu meydana gelen bir küme şeklinde tanımlanmaktadır (Lu vd., 2012: 311). Bu kümeye ise “Mandelbrot Kümesi” denilmektedir. Fraktal geometride her bir parça, tüm yönlerde aynı indirgeme oranlarına sahip, bütünün doğrusal bir geometrik indirgemesidir” şeklinde ifade edilir ve “Parçalar, ne kadar küçük olursa olsun, bütüne benzer” diyerek açıklanmaktadır. Yani fraktallar, temelde baz alınan öz parçacığın benzerliğe sahip olan sonsuz genişleyebilen bir bütünsellikle ifade edilebilmektedir. Temsil edilen bu bütünlük içerisinde her bir parça yine fraktalın öz parçasını taşımaktadır. Eşitlik (4.1)’de görülen Mandelbrot kümesi $f(z)$ fonksiyonun karmaşık sayılar düzlemindeki z parametresinin karesi alınarak sabit bir sayının eklenmesiyle oluşmaktadır (Lu vd., 2012: 311). Aslında çok basit matematiksel denklemler veya yinelemeli süreçler ile farklı karmaşık fraktal yapılar oluşturulabileceği sonucuna varılmaktadır.


$$f(z) = z^2 + c \quad (4.1)$$

Evrişim mimarisinde derin ağlar geliştirmek oldukça önemlidir. Fraktal yapısının enine ve boyuna genişleyen özelliği evrişim modeli geliştirmek için oldukça ilham verici olmuştur. Bu bağlamda, (Larsson vd., 2016) tarafından fractal geometrisinden esinlenerek geliştirilmiş olan Fractal-Net evrişim blok yapısında giriş ve çıkış arasında tek bir evrişim yapısı $f_c(z)$ olarak ifade edilmektedir. Her bir genişleme ise $f_{c+1}(z)$ olarak formülize edilmektedir. Soldan sağa doğru bakıldığında c kadar içiçe geçmiş sütunlar 2^{c-1} kadar evrişim yapısına sahiptir. Her bir giriş çıkış katmanı arasında kalan fraktal evrişim bloğunun çokluğu kadar ağı derinleştirmek mümkündür (Larsson vd., 2016). Fractal-Net yapısında Eşitlik (4.2)’deki ifade kullanılırken, kendi U-Net mimarimiz için özelleştirilmiş fraktal yapısı için eşitlik (4.3) kullanılmaktadır ve Şekil 4.17’de modellenmesi gösterilmektedir.

$$f_c(z) = \text{conv}(z) \quad (4.2)$$


$$f_c(z) = \text{conv}(z) + \text{BN}(z) + \text{Activation}(\text{ReLU}(z)) \quad (4.3)$$

Fractal-Net içerisinde genişleyen evrişim yapısı sayesinde daha derin bir mimari yapılandırmasına olanak sağlamaktadır. Mimarinin blok yapısı her adımda 2^n şeklinde genişlemekle beraber her biri farklı alt yollar ile birbirine bağlanmaktadır. Fractal yapısının böylesine genişlemesi aşırı derin evrişimli ağ yapısı elde edilebileceğini göstermektedir.



Şekil 4.17. U-Net evrişim blok yapısı(a), FractalSpiNet evrişim blok yapısı(b)


Önerilen FractalSpiNet temelinde olan ve Şekil 4.18.'de gösterilen fraktal evrişim yapısı içerisinde farklı bağlantıları pasif ederek farklı evrişim blokları elde etmek mümkündür (Rukiye Polattimur vd., 2024). Klasik U-Net mimarisinde kullanılan konvolüsyon, batch normalizasyonu ve aktivasyon fonksiyonu işlem sırası yine fraktal evrişim yapısına entegre edilmiştir. Bu yapı aslında farklı evrişim yapılarını içinde tutan farklı tensörler olarak adlandırmak mümkündür ve bu tensörlerin en büyük özelliği kanal sayısı önceki dönüşüm katmanındaki filtre kümesinin boyutuna karşılık gelmesidir. Bu özellik sayesinde U-Net mimarisinin kodlama ve kod çözücü bloklarına entegre edilmesi ek bir işlem olmadan oldukça kolay uygulanabilmektedir. Fraktal genişledikçe ağın derinliğini artırmak mümkündür fakat derinlik arttıkça ağın eğitimi ve optimize edilmesi zorlaşmaktadır.



Şekil 4.18. Fraktal evrişim yapısı basit yapıdan genişleyen yapıya doğru a, b, c sırasıyla ilerlemektedir. FractalNet evrişim temel yapısı $f_c(z) = \text{conv}(z)$ (a), 2^{c-1} evrişimiyle genişleyen fraktal yapı ikinci genişlemede b'de, üçüncü genişlemede c'deki gibi ilerlemektedir. c'de görüldüğü gibi her evrişim bloğu bir evrişim, batch normalizasyon ve ReLu aktivasyon fonksiyonu olarak tasarlanmıştır

U-Net mimarisine entegre edilen fraktal yapısı kullanılarak geliştirilen FractalSpiNet mimarisinin tam yapısı Şekil 4.19.'da sunulmuştur. Bu mimaride, derinliğin optimum düzeyde tutmak için fayda zarar ilişkisinde modelin eğitim süresince elde edilen metrik performanslarına olan katkısı ölçüsünde değerlendirilmiştir. Nitekim ağı istenildiği kadar genişletmek mümkündür fakat en derin ağı tasarlamak model için her zaman en optimum sonucu vermemektedir. Bu bağlamda 2^{C-1} kadar evrişim yapısında c sayısı ağı derinliğini belirlemektedir. Kodlama bloklarına entegre edilen fraktal yapılar aşağı yönlü alt örnekleme uygulanarak kod çözücü yönünde ise giriş görüntüleri için bir bölütleme maskesi oluşturmak amacıyla üst örnekleme ve tersine evrişim işlemleri uygulanmaktadır. Klasik evrişim blok yapısında olduğu gibi fraktal evrişim bloğuda konvolüzyon, batch normalizasyon ve aktivasyon (ReLU) olarak kullanılmaktadır. U-Net mimarisinde modelin işlem adımları aynı şekilde ilerlemekte

olup modelin evriřim yapısı deęiřtirilerek yeni önerilen evriřim bloęunun modele olan katkısı incelenmiřtir.



řekil 4.19. Tez alıřması kapsamında geliřtirilen U-Net tabanlı FractalSpiNet mimarisinin aık hali

4.5.2. Con-FractalSpiNet

Tez alıřması kapsamında U-Net mimarisi tabanlı geliřtirilen dięer bir mimari Con-FractalSpiNet olarak isimlendirilmiřtir. Bu mimaride de, katman birleřtirme olarak adlandırılan, kodlama ve kod özücü bloęa doęrudan baęlantı saęlayan baęlantıya fraktal evriřim yapısının entegrasyonu ile gerekleřtirilmiřtir. Bu baęlantı, bařlangı evriřim yapılarında bulunan konum ve baęlam bilgisi kaybolmadan aktarılması saęlanmaktadır. Burada kullanılan direk baęlantı yapısı mevcut herhangi bir evriřim aęı kullanılmadan kodlama bloęundan karřı blok yapısında bulunan kod özücü yapısına eklenmektedir. Klasik U-Net mimarisinde konum ve baęlam bilgisini aktarımı direkt olarak yapılırken yeni mimaride fractal evriřim bloęu kullanılarak baęlantı yapılmaktadır. Bu sayede öznitelikler yeniden evriřim iřlemine tabi tutularak yeni bir özellik haritası ile kod özücü bloęa aktarımı saęlanmaktadır. řekil 4.20.'de göröleceęi gibi klasik U-Net yapısının katman birleřtirme

bağlantısına FractalNet blok yapısı entegre edilerek yeni model Con-FractalSpiNet gösterilmiştir.

Şekil 4.20. Tez çalışması kapsamında geliştirilen U-Net tabanlı Con-FractalSpiNet mimarisinin açık hali

Tez çalışması kapsamında öneilen bir diğer yapı ise Att-FractalSpiNet olarak adlandırılmıştır ve U-Net modellerinde daha önce karma modellerde karşımıza çıkan dikkat (attention) yapısı ile gerçekleştirilmiştir. Dikkat mekanizmasının verisetlerinde gösterdiği başarı birçok farklı U-Net mimarilerlerinin tasarımına ilham olmuştur. Bu nedenle yeni modelin geliştirilmesinde en önemli motivasyon attention derin öğrenme modelinin klasik U-Net modeline entegre edilerek yapılmış olan yeni modelin başarısının oldukça yüksek olmasıdır. Görüntü bölütleme çalışmalarında amaç ilgili bölgenin bölütlenmesi hedeflenirken görüntülerde var olan gereksiz alanların (arka plan) gözardı edilmesi beklenir. Attention (dikkat&özen) modeli eğitim süresi boyunca sadece ilgili alanları kullanarak hesaplama maliyetini azaltıp ağır daha iyi genelleştirmesine yardımcı olmaktadır.

5. DENEYSEL SONUÇLAR

Tez çalışması kapsamınca omurilik alanı, beyin omurilik alanı ve omurilikte MS lezyonlarının tespit edilmesi gibi farklı bölütleme çalışmalarını gerçekleştirmek için temel U-Net mimarisi, karma U-Net mimarileri ve önerdiğimiz FractalSpiNet mimarileri kullanılarak birçok bütüncül bir bölütleme ve tespit çalışması gerçekleştirilmiştir.

Servikal omurilik aksiyel ve sagittal MR verileri kullanarak bölütlenmesi hedeflenen alanların ayrı ayrı maskeleme işlemleri yapılarak alt veri grupları oluşturulmuştur. Aksiyel çekimler kullanılarak OKA ve BOS işaretlemeleri yapılarak omurilik aksiyel OKA/BOS veri alt grubu oluşturulmuştur. Yine servikal omurilik MR verileri içerisindeki aksiyel ve sagittal verilerde omurilik ve MS lezyon alanlarının işaretlenmesi yapılarak omurilik aksiyel MS ve omurilik sagittal MS veri alt grupları oluşturulmuştur. Dolayısıyla, servikal omurilik MR verileri ile Tablo 5.1.'de verilen toplam üç adet birbirinden farklı ve özgün veri seti alt grupları hazırlanmıştır. Diğer taraftan, özgün verisetine ek olarak açık kaynak veri seti olan SCGMSC veriseti de çalışma kapsamınca bölütleme çalışmalarında değerlendirilmiş ve elde edilen sonuçlar önerilen mimarilerin sonuçları ile karşılaştırılmıştır. Deneysel çalışmalarda, temel U-Net mimarisi başta olmak üzere karma U-Net mimarilerinden Att U-Net, Res U-Net, Att-Res U-Net mimarileri ve önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarileri sonuçları değerlendirilmiştir. Deneysel analizlerde, omurilik bölgesi ve beyin omurilik alanı, gri maddenin otomatik bölütlenmesi ve MS lezyonlarının tespiti yapılmıştır.

Tablo 5.1. Tez çalışması kapsamında deneysel çalışmalarda kullanılan tüm verisetleri ve derin öğrenme mimarileri

Verisetleri	Derin öğrenme mimarileri
1-Servikal Omurilik MR Veriseti (Özgün) • Omurilik Aksiyel OKA/BOS • Omurilik Aksiyel MS • Omurilik Sagittal MS	Temel mimari
	U-Net
	Hibrit U-Net modelleri
	Att U-Net
	Res U-Net
2-SCGMSC (Açık Kaynak Omurilik Aksiyel GM/BM)	Att-Res U-Net
	Önerilen U-Net tabanlı mimariler
	FractalSpiNet
	Con-FractalSpiNet
	Att-FractalSpiNet

5.1. Optimize Edilen Hiper Parametreler

U-Net modelinin başarısını etkileyen bazı önemli hiperparametreler vardır. Model eğitimlerinde hiperparametre seçimi ağırlıkla daha az maliyetle daha yüksek başarımlar elde etmesi temeline değerlendirilmektedir (Atlan vd., 2020: 60; Feurer ve Hutter, 2019: 3).

Tüm seçilen hiperparametreler modelin eğitim sürecini ve performansını etkileyen ayarlarını ve sayısal değerlerini ifade etmektedir. Bu hiperparametreler, genellikle deneme yanılma yöntemiyle belirlenir veya literatürde sıklıkla başarılı olan parametreler seçilerek ön model kurulmakta ve modelin verimliliği üzerindeki etkileri model aşamalarında değiştirilerek en optimum değerlerin kullanması sağlanmaktadır (Gülcü ve Kuş, 2019: 503; Yu ve Zhu, 2020). Hiperparametreler model tasarım aşamasından model eğitim süreçlerine birçok adımda karar verilmesi gereken parametreleri içermektedir.

Model tasarım aşamasında kanal sayısı, filtre boyutu, katman sayısı, havuzlama değerleri, aktivasyon fonksiyonu seçimi, yukarı örnekleme yöntemleri, çıkış fonksiyonları ve atlama bağlantılarının nasıl yapılacağı konularının değerlendirilmesi ve elde edilen sonuçlara göre yapılacak olan U-Net mimarilerinin performans sonuçları ayrı ayrı hesaplanması gerekmektedir. Model tasarımını etkileyen yenilik katan tüm aşamalar bu özelliklerin aldığı değerlere göre şekillenmektedir. Öte yandan, modelin kurulumu sonrasında, eğitim sürecinde ağırlıkların güncellenmesi, öğrenme hızı gibi parametrelerin seçimi ve farklı veri setleriyle yapılan çapraz doğrulamalar yoluyla model performansının nihai sayısal değerlere ulaşması, büyük bir titizlikle takip edilmesi gereken adımlardır. Model süresi boyunca öğrenme eğrileri ve doğrulama performansları izlenerek hiperparametrelerin modele olan olumlu olumsuz katkıları değerlendirilmektedir. En doğru parametre seçimleri ile U-Net mimarisinin başarılı sonuçlarını daha da artırması ile model öğrenme kapasitesinden maksimum ölçekte fayda sağlaması beklenmektedir. Tez çalışmasında, tüm mimariler için kullanılan hiperparametreler Tablo 5.2.'de verilmiştir. Tüm modellerin başarımlarını değerlendirirken eşit bir kıyaslama yapabilmek için optimum ölçekte modele katkı sağlayacak parametreler seçilerek model eğitimleri gerçekleştirilmiştir.

Tablo 5.2. U-Net ve diğer tüm modeller için tercih edilen hiperparametre değerleri

Epok (Epoch)	200
Yığın boyutu (Batch size)	8
Öğrenme oranı (Learning rate)	0.001
Seyreltme (Dropout)	0.5
Aktivasyon fonksiyonu (Activation function)	ReLU
Çıkış aktivasyon fonksiyonu (Output activation function)	Sigmoid
Optimizasyon algoritması (Optimization algorithm)	Adam
Kayıp fonksiyonu (Loss function)	İkili çapraz entropi (Binary cross entropy)

Deneyisel çalışmalarda kullanılan tüm hiperparametreler derin öğrenme modellerinin eğitim süresinde, modelin performansı üzerinde ve modelin genelleme yeteneğinde oldukça kritik bir öneme sahiptir. Tüm parametreler ayarlanabilir veya farklı

seenekler dahilinde modele olan katkısı incelenebilmektedir. Modelin davranışını kontrol etmek, eğitim süresini kontrol etmek, aşırı uydurmayı önlemek, optimizasyon algoritmalarını ayarlamak, model performansını iyileştirmek gibi birçok hiperparametre özellikleri ile derin öğrenme modellerinden elde edilecek performansı en yüksek değeri ulaştırmak mümkün olabilmektedir. Fakat modellerin kurulmasında en uygun hiperparametre gibi bir durum olmamakla beraber çoğu zaman deneme yanılma yöntemiyle bu değerlerin optimize edilmesi gerekmektedir.

Öğrenme oranı (learning rate), derin öğrenme modellerinde modelin hızlı veya yavaş öğrenmesine karar veren önemli bir hiperparametre değeridir. Yüksek öğrenme oranı modelin daha hızlı öğrenmesini sağlayarak eğitim süresini kısa sürmesini sağlayabilmektedir. Fakat bu durum aynı zamanda eğitim aşamasında büyük dalgalanmalara neden olabilmektedir. Öğrenme oranını daha düşük tutulması halinde ise daha stabil bir eğitim süreci geçirmesini sağlar ama bu durumda eğitim süresinin oldukça uzamasına neden olarak yerel minumumlara kolayca takılabileceği durumlara sebep verebilmektedir.

Batch boyutu (yığın boyutu), derin öğrenme hiperparametrelerinde çok önemli bir değer olup model sonucunu önemli ölçüde etkileyebilmektedir. Derin öğrenmede yığın boyutu modelin bir eğitim adımında işlediği örneklerin sayısını belirlemektedir. Yani, bir yığın boyutu ağı ne kadar sıklıkla güncelleneceğini belirlemektedir. Yığın boyutu bilgisayarın hesaplama gücü ile direkt ilişkilidir. Diğer taraftan özellikle veri setinin boyutu, mimarının total parametre sayısı ve donanımsal yeterlilik durumları en uygun değeri belirlemek için dikkate alınması gereken kriterlerdir.

Epok sayısı (Epochs), tüm veri setinin eğitim aşamasında bir kez kullanılması bir epok değerine karşılık gelmektedir. Epok aldığı değer ölçüsünce modelin eğitim süresi boyunca tüm verisetini kaç kere kullanacağı anlamına gelmektedir. Model eğitimleri sonunda model ve veri seti uyumunu takip edebilmek için eğitim kaybı ve doğrulama kaybı gibi grafikler incelenmektedir. Eğitim kaybı model veri setini uyumunu gösteren bir değer iken doğrulama kaybı ise modelin genelleme yeteneği açıklamakta olup aşırı öğrenmeyi engellemek için bir veri sunmaktadır. Kısaca epok değeri modelin eğitim sürecini ve performansını ölçme ve değerlendirmek için önemli bir parametredir.

Aktivasyon fonksiyonları (Activation functions), genel olarak yapay sinir ağlarında kullanılan aktivasyon fonksiyonları farklı matematiksel işlevselliği ile her katmanın çıktısını istenilen değer bazında sonuçlanmasını sağlamaktadır. ReLU (Rectified Linear Activation) evrişim sinir ağlarında en çok kullanılan fonksiyon olmakla

beraber ikili sınıflandırma problemlerin çözümü için sigmoid, çoklu sınıflandırma problemleri için softmax kullanılmaktadır.

Seyreltme oranı (Dropout oranı), derin öğrenme modellerinde sıklıkla kullanılan ve temeli birçok parametreye dayanan overfitting denilen aşırı uydurmayı azaltmak için kullanılan bir regülerizasyon tekniğidir. Aşırı uydurma (overfitting) durumları model eğitimleri esnasında sık yaşanan problemlerin başında gelmektedir ve aşırı uydurma sebebiyle model veri seti ile olan uyumu azaltarak yeni verilere olan genelleme yeteneğini kaybetmektedir veya azalmaktadır.

Momentum, derin öğrenme modellerinde ve gradyan inişi optimizasyon algoritmalarında kullanılan gradyan iniş hızını stabilize etmek için tercih edilen bir tekniktir. Momentum her bir eğitim adımında önceki adımların bir ortalamasını alarak gradyan güncellemelerini düzenleyerek birleştirmektedir. Bu nedenle momentum değeri ile gradyan inişi sırasında hızını ayarlayarak modelin eğitim sürecini hızlandırarak yerel minimumlardan daha hızlı ve sorunsuz çıkmasına yardımcı olabilmektedir.

Optimizasyon algoritması, modelin parametre değerlerinin eğitim veri seti ile en uygun şekilde güncellenmesini sağlamaktadırlar. Genellikle derin öğrenme modellerinde Adam optimizasyon algoritması kullanılmasına karşılık RMSProp, SGD, AdaGrad, Adadelta, Nadam ve Gradient Descent gibi kullanılan birçok popüler algoritmalar da mevcuttur.

Batch normalizasyon, ağı daha hızlı ve daha istikrarlı bir şekilde eğitilmesine yardımcı olan ve daha iyi genelleme yeteneğine sahip olmasını sağlayan bir normalizasyon tekniğidir. Batch normalizasyon modele olan katkıları sırasıyla değişkenliklerin azalmasını sağlamaktadır, aşırı öğrenmenin önüne geçerek modelin genelleme yeteneğini artırmaktadır ve son olarak gradyan inişinin daha kararlı olmasını sağlayarak eğitim süresini kısaltmaktadır şeklinde ifade edilebilmektedir.

5.2. Performans Metrikleri

U-Net mimarisinde performans kriterleri model eğitimleri sonucunda bölütleme başarısını değerlendirmek için kullanılan çok önemli matematiksel araçlardır. Eğitim sonunda maske ve orijinal görüntüler kullanılarak yapılan bir sınıflandırma probleminin/işleminin ne kadar başarılı olduğunu anlamak için çeşitli değerlendirme kriterleriyle sonuçlarımızı analiz etmek ve modelin tahmin edebilme yeteneğinin sayısal sonuçlarını çıkarmak için metrikler kullanılmaktadır.

Tez çalışması kapsamınca yapılan deneysel çalışmalar sonucunda servikal omurilik bölgesinin ve beyin omurilik sıvısı alanının bölütlenmesi ve MS lezyonlarının tespitini değerlendirmek için önemli anahtar metrikler kullanılarak model başarıları değerlendirilmiştir. Bunlardan en önemli metrik olan ve Eşitlik (5.1)'de verilen Dice benzerlik katsayısı (DSC) altın standart (gerçek/uzman) maske ile bölütleme sonucu tahmin maskesi arasındaki bölütleme oranını göstermekte olan model başarısını değerlendirmek için literatürde en sık tercih edilen metriktir. Bu iki maske verisi arasında ilişki (eşleşme/örtüşme) ne kadar yüksek ise başarımlar o kadar yüksek olmaktadır. Aldığı değer 0 ile 1 arasında olup 1 ile yüzde yüz örtüşmeyi, 0 ile hiçbir benzer piksel örtüşmesi olmadığını göstermektedir.

Eşitlik (5.2)'de verilen hacimsel bazlı benzerlik tespitleri için kullanılan hacimsel örtüşme hatası (Volume overlap error, VOE) ile Eşitlik (5.7)'deki göreceli hacim farkı (Relative Volume Error, RVD) metrikleri başarı ölçütü olarak model eğitimleri sonunda kullanılmıştır. VOE metriği kullanılarak tahmin edilen bölütleme ve altın standart bölütleme arasındaki "birleşim" ve "kesişim" hacimlerinin hesaplanması sonucu elde edilmektedir. RVD ise tahmin edilen ve gerçek maske hacmi arasındaki farkı hesaplamaktadır. RVD ile bölütlemenin hacimsel doğruluğu ölçülerek doğruluk değeri hesaplanmaktadır.

Bunların yanı sıra mesafe bazlı değerlendirme metrikleri olan Eşitlik (5.3), Eşitlik (5.4) ve Eşitlik (5.5)'teki Hausdorff mesafesi 95 (HD95), son olarak Eşitlik (5.6)'daki ortalama yüzey mesafesi (Average Symmetric Surface Distance, ASD) metrikleri ile modellerin mesafe bazlı değerlendirilerek başarı ölçütleri çıkarılmıştır. Hausdorff mesafesi ile iki küme arasındaki en uzak nokta çifti arasındaki maksimum mesafeyi ölçmekte ve bu metrik genellikle bölütlenen kenarlar arasındaki maksimum hatayı belirlemektedir. HD95 (95. Persentil Hausdorff Mesafesi) HD'nin 95. persentilini ifade etmekte olup kısaca en büyük %5'lik mesafe ihmal edilerek kalan %95'lik mesafelerin en büyüğü hesaplamaya katılarak maksimum uç değerinin etkisini azaltılmakta ve daha kararlı bir ölçüm sağlamaktadır. Daha düşük değerler daha iyi bölütleme anlamına gelirken aksiyel MS lezyonları gibi küçük fakat klinik olarak önemli sınırların hataları algılayabilmek için önemli bir ölçek değeri olarak kullanılmaktadır. ASD metriği sayesinde model bölütlemenin sınırları arasındaki ortalama mesafeyi ölçmektedir. Bu iki yüzey arasındaki tüm noktaların mesafelerinin ortalaması alınarak hesaplanmakta ve genel bir hata ölçüsü sağlamaktadır.

$$DSC (PM, GM) = \frac{2 \times |PM \cap GM|}{|PM| + |GM|} \times 100 \quad (5.1)$$

$$VOE (PM, GM) = (1 - \frac{|PM \cap GM|}{|PM| + |GM| - |PM \cup GM|}) \times 100 \quad (5.2)$$

$$hd(PM, GM) = \max_{x \in PM} \min_{y \in GM} \|x - y\|_2 \quad (5.3)$$

$$hd(GM, PM) = \max_{y \in GM} \min_{x \in PM} \|x - y\|_2 \quad (5.4)$$

$$HD95(PM, GM) = \max(hd(PM, GM), hd(GM, PM)) \quad (5.5)$$

$$ASD(PM, GM) = \frac{1}{|s(PM)| + |s(GM)|} \left(\sum_{S_{PM} \in S(PM)} d(S_{PM}, S(GM)) + \sum_{S_{GM} \in S(GM)} d(S_{GM}, S(PM)) \right) \quad (5.6)$$

$$RVD(PM, GM) = (\frac{|PM| - |GM|}{|GM|}) \times 100 \quad (5.7)$$

$$REC (PM, GM) = \frac{TP}{TP + FN} \times 100 \quad (5.8)$$

$$PRE (PM, GM) = \frac{TP}{TP + FP} \times 100 \quad (5.9)$$

Karışıklık matrisi değerleri gerçek pozitif (TP), yanlış pozitif (FP), yanlış negatif (FN) ve gerçek negatif (TN) olmak üzere karışıklık matrisi değerlerini kullanarak birçok değerlendirme metriği hesaplamak mümkündür. Duyarlılık (Recall, REC) Eşitlik (5.8) denklemi ile model tarafından doğru tahmin edilen piksellerin gerçek doğru piksellere oranı tespit edilmektedir. Kesinlik (Precision, PRE) ise Eşitlik (5.9) denklemi ile pozitif olarak tahmin edilen değerlerden kaçınan gerçekten pozitif değerleri göstermektedir. Kullanılan metrikler için denklemlerde PM (tahmin edilen maske, predict mask), önerilen yöntemle elde edilen bölütleme sonucunu temsil ederken, GM (gerçeklik maskesi, uzman maskesi, ground thruth) uzman radyolog tarafından maskelenen referans alanı temsil etmektedir.

5.3. Yazılım ve Donanımsal Altyapı

Derin öğrenme modellerinin gelişim süreçlerini etkileyen en önemli 2 etken donanımsal yeterlilik ile kolay ve uygulanabilir yazılım geliştirilmesi olarak göstermek mümkündür. Derin öğrenme alanında CPU (Central Processing Unit), GPU (Graphics Processing Unit) ve TPU (Tensor Processing Unit) gibi işlemci türlerinin gelişimi, derin öğrenme modellerinin eğitimi ve uygulanması için kullanılan donanım altyapısında önemli değişikliklere neden olmuştur. CPU'lar derin öğrenme modellerinin ilk yıllarında vardı fakat derin mimarileri büyüklüğü ve karmaşıklığı arttıkça bu teknoloji ile hedeflenen başarılar elde edilememiştir. Özellikle paralel hesaplama kabiliyeti olmadığı için derin öğrenme modelinin büyük boyutlu verilerle çalıştığı zamanlarda eğitim ve

çıkartım süreleri oldukça uzun sürmüştür. GPU grafik işleme birimleri ise genellikle grafiksel uygulamaları hızlandırmak için kullanılırken sahip oldukları paralel hesaplama yetenekleri sayesinde derin öğrenme modellerinin eğitimi ve çıkartımını büyük ölçüde hızlandırmışlardır. Özellikle NVIDIA'nın CUDA platformu derin öğrenme çalışmalarında GPU kullanımını arttırmıştır. Google tarafından geliştirilen özel bir donanım çeşidi olan TPU'lar ile tensor işleme görevlerine (özellikle derin öğrenme modellerinde sıkça kullanılan tensor işlemleri) odaklanmışlardır. TPU teknolojisi sayesinde oldukça büyük verisetlerinin kullanımında derin öğrenme mimarilerinin eğitim sürelerine olumlu katkı sunarak daha düşük enerji tüketimiyle daha yüksek performans sağlayabilmektedir. Bu özellikleri TensorFlow, Keras ve Google'ın sunduğu bulut tabanlı çalışma ortamlarında (Colab) oldukça uyumlu olarak çalışabilmektedir. Bu sayede büyük verisetleri ile çalışmak zaman ve verim açısından daha makul hale gelmiştir. Tüm bu donanımsal gelişim süreci derin öğrenmenin aşama aşama yaygın olarak benimsenmesine ve çok çeşitli uygulama alanlarında kullanılmasına önemli bir katkıda sunmuştur.

Derin öğrenme mimarilerinin gitgide daha kompleks bir hale gelmesi kullanılan yazılım dilinin ve yazılım araçlarının pratikleşmesini sağlamıştır. Sürekli güncellenerek yeniliklerin sunulduğu bu alanda, gelişim ve yenilikler oldukça hızlı olmaktadır. Bu çerçevede birçok yazılım araçları ve dili geliştirilmiştir. En çok kullanım alanına sahip kütüphaneler: TensorFlow, PyTorch, Keras, MXNet, Caffe, ONNX olarak sıralamak mümkündür. Derin öğrenme kütüphaneleri ile uyumlu çalışması sayesinde yaygın bir kullanıma sahiptir. İnteraktif kullanımları sayesinde model aşamalarını sırasıyla işletebilmekte, model çıktılarınızı görselleştirebilmekte ve sonuçları analiz edilebilmektedir. Bazı popüler IDE arayüzleri: PyCharm, Visual Studio Code (VS Code), Spyder, Google Colab ve Jupyter Notebook olarak belirtilebilmektedir. Tezde yapılan deneysel çalışmaların tamamında Tablo 5.3.'te detayları verilen donanımlarına sahip bir bilgisayar kullanılarak tamamlanmıştır. Tez çalışmasının bu bölümünde deneysel çalışmalar kapsamında bütüncül olarak omuriliğin otomatik bölütleme için tüm aşamalarda ITK-SNAP yazılımı ve Python programlama dili ile Jupyter Notebook IDE kullanılmıştır.



Tablo 5.3. Çalışmada kullanılan bilgisayarın donanımsal yapısı ve teknik özellikleri

Donanım	Özellikler
CPU	Intel® Core™ i5-10600KF, 4.10 GHz, 6 Core / 12 Thread
RAM (x2)	16 GB (DDR4 3000 Mhz)
Mainboard	ASUS B560
GPU	NVIDIA RTX™ A4000 16 GB GDDR6
Harddisk	1TB WD SATA 6G HDD+500GB PCIe NVMe M.2 SSD

5.4. Omurilik Aksiyel OKA/BOS Alt Veri Kümesinde Elde Edilen Sonuçlar

Bu aşamada, servikal omurilik T2a MR verilerini kullanarak oluşturduğumuz ilk özgün veri grubumuz ile OKA ve BOS alanların bölütleme çalışmasını gerçekleştirilmiştir. Alt veri kümesinde 20 MR taraması kullanılarak toplam 500 adet görüntü ve maske elde edilmiştir. Deneysel çalışmalar kapsamında, veri artırma tekniği kullanılarak veri seti 1000 olarak genişletilmiştir. Bu veri alt kümesi Tablo 5.4.'te görüldüğü gibi %80 eğitim ve %20 test olarak ikiye ayrılmıştır. Bölütleme işlemi için temel U-Net mimarisi başta olmak üzere karma U-Net mimarilerinden Att U-Net, Res U-Net, Att-Res U-Net mimarileri ve önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarileri kullanılarak birçok deneysel çalışma gerçekleştirilmiştir. Model eğitimleri sonucunda modelin çalışma performansını değerlendirmek için eğitim ve değerlendirme doğruluk (accuracy) grafikleri, zaman ve parametre ilişkisinin değerlendirilmesi, model başarıları oranlarının sayısal değerleri için DSC (%), VOE (%), HD95 [mm], ASD [mm], RVD (%), REC (%), PRE (%) metrik değerlerinin hesaplanması gerçekleştirilmiştir. Ayrıca tüm test kümesi verisi için model tahmin yeteneğini gözlemleyebilmek için MR verisi, MR maske verisi ve model eğitimleri sonucunda elde edilen tahmin maskeleri tek tek çıkartılmıştır. Bu sayede piksel bazlı benzerlik oranları ve metrik değerleri tüm test kümesi için tek tek hesaplanarak ortalaması alınmıştır.

Tablo 5.4. Omurilik aksiyel OKA/BOS veri detayları

	MR görüntüsü	Uzman Maskesi	Teknik Detaylar	Boyut	Eğitim kümesi	Test kümesi
Omurilik Aksiyel OKA/BOS			Aksiyel MR T2a	128x128 .jpg	800 (%80)	200 (%20)

Deneysel çalışmalarda, temel U-Net mimarisi, Att U-Net, Res U-Net, Att-Res U-Net mimarileri ve önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarilerinin performans sonuçları karşılaştırılmıştır. Bu mimariler farklı katman ve bağlantı yapılarına sahip olduğu için toplam parametre sayıları birbirinden oldukça farklı değerlere sahiptir. Bu durum eğitim süresini etkileyen en önemli etkenlerdendir. Parametre sayısı ile eğitim süresi arasında doğru orantılı bir ilişkiye sahip olduğu Tablo 5.5.'te daha detaylı incelendiğinde gözlemlenecektir.


Tablo 5.5. Omurilik aksiyel OKA/BOS alt veri kümesi model parametre sayısının 200 epoch için model eğitim süresi, model doğruluk ve IoU sonuçları

Omurilik Aksiyel OKA/BOS	Parametre	Zaman	Doğruluk(%)	IoU (%)
U-Net	31,401,349	0:27:17	98.93	80.06
Att U-Net	37,333,513	0:33:39	98.90	67.40
Res U-Net	33,156,933	0:32:39	98.92	66.62
Att-Res U-Net	39,089,097	0:39:19	98.90	71.13
FractalSpiNet	109,922,693	1:27:25	98.93	78.14
Con-FractalSpiNet	53,369,029	0:57:07	98.92	72.77
Att-FractalSpiNet	115,854,857	1:35:05	98.92	79.78

Model eğitimleri aşamasında her bir epok için doğruluk (accuracy) değeri hesaplanarak model sonucunda bir değerlendirme grafiği elde edilmektedir. U-Net mimarisinde, eğitim doğruluğu (training accuracy) ve doğrulama doğruluğu (validation accuracy) grafikleri modelin performansı, genelleme yeteneği ve olası sorunları hakkında önemli bilgiler vermektedir. Bu grafikler, eğitim süreci boyunca modelin nasıl öğrendiğini ve bu öğrenmenin doğrulama verisi üzerinde nasıl genelleştirildiğini anlamak için araştırmacılar tarafından sıklıkla kullanılmaktadır. Eğitim doğruluğu modelin eğitim veri seti üzerinde doğru tahmin ettiği örneklerin oranını gösterirken doğrulama doğruluğu modelin test veri seti üzerinde doğru tahmin ettiği örneklerin oranıdır. Bu, modelin eğitilmediği verilere karşı nasıl performans gösterdiğini değerlendirmek için önemli bir parametredir. Diğer taraftan eğitim kaybı (training loss) modelin eğitim verisi üzerinde tahmin ettiği değerlerin gerçek değerlerden ne kadar saptığını ifade etmektedir. Doğrulama kaybı (validation loss) modelin test verisi üzerinde tahmin ettiği değerlerin gerçek değerlerden ne kadar saptığını göstermektedir. Başarılı bir eğitim grafiğinde hem eğitim hem de doğrulama doğruluğu zamanla artar ve birbirine yakın değerler alırsa eğer bu genellikle modelin hem eğitim verisi üzerinde iyi öğrendiğini hem de öğrendiklerini test verisi için başarıyla genelleştirdiğini göstermektedir. Kayıp grafikleri için ise durum eğitim kaybı ve doğrulama kaybı zamanla azalma seyri izlerken eğitim sonunda ulaşabileceği en düşük seviyelere inmektedir.

Şekil 5.1(a, b, c,d)’de omurilik aksiyel OKA/BOS alt veri kümesinde, model eğitimleri sonunda, eğitim kaybı, eğitim doğruluğu, doğrulama kaybı ve doğrulama doğruluğu grafikleri U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet için elde edilen görseller verilmiştir. Eğitim doğruluğu ve eğitim kaybı grafikleri oldukça beklenen seyrinde bir sonuç elde edilirken doğrulama

kaybı ve doğrulama doğruluğu grafiklerinde test kümesinde Att-Res U-Net modelinde en yüksek pik değerleri elde edilmiştir. Bu durum test verisinin değerlendirilmenin bu aşamasında modelin zorlandığı ve hata aldığı bir anı göstermektedir. Bu büyüklükte olmasa da diğer modellerde değerlendirme doğruluğu grafiğinde farklı aşamalarda modelde pikler görmek mümkündür.



Şekil 5.1. Omurilik Aksiyel OKA/BOS verisi için U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet model eğitimleri sonucunda elde edilen (a) eğitim kaybı, (b) eğitim doğruluğu, (c) doğrulama kaybı ve (d) doğrulama doğruluğu değerlerinin grafikleri (200 epok, batch size=8)







Servikal omurilik boyunca aksiyel OKA ve BOS'un bölütlemesi ve MS lezyonlarının tespiti için önerilen FractalSpiNet modelleri ve diğer U-Net, Att U-Net, Res U-Net, Att-Res U-Net mimarileri eğitimleri sonucunda elde edilen metrik sonuçları Tablo 5.6.'da, Tablo 5.7.'de, Tablo 5.8.'de ayrı ayrı gösterilmiştir. Burada, tüm metrik değerleri DSC (%), VOE (%), HD95 [mm], ASD [mm], RVD (%), REC (%), PRE (%) test veri setinde bulunan tüm görüntüler için ayrı ayrı hesaplanarak ortalama skor çıkarılmıştır. Bölütleme başarısı her MR dilimi için hesaplanan metrik sonuçlarının ortalaması alınarak elde edilmiştir ve sonuçlar ayrıntılı olarak verilmiştir. Tüm modeller için 200 epok (tur) sayısı için model metrik değerleri hesaplanmıştır.

İlk olarak OKA için bölütleme sonuçları hesaplanarak Tablo 5.6’da verilmiştir. Con-FractalSpiNet kullanılarak DSC sonuçlarının %94.99 ile servikal omurilikteki OKA bölgesini segmentlemede daha başarılı olduğunu görülürken, hemen ardından U-Net %94.94 ve FractalSpiNet %94.90 ile birbirine oldukça yakın skorlar ile başarılı bir şekilde bölütleme sağlamışlardır. Diğer taraftan, sırasıyla Res U-Net %94.79, Att-FractalSpiNet %94.70, Att U-Net %93.37 ve Att-Res U-Net %92.37 gibi oldukça yüksek DSC skorları elde edilmiştir. Ayrıca, ASD ve VOE gibi metriklerin sonuçlarında da önerilen Con-FractalSpiNet ile daha başarılı iken, RVD metrik sonucunda FractalSpiNet ve Con-FractalSpiNet modellerinde en iyi değerlere sahiptir. HD95 için ise en başarılı sonuç U-Net mimarisi ile elde edilmiştir. Att-Res U-Net mimarisinde, eğitim sonuçları değerlendirildiğinde en az başarılı sonuçlar elde edilmiştir.

Tablo 5.6. Omurilik Aksiyel OKA/BOS alt veri kümesinde FractalSpiNet mimarileri ve diğer U-Net mimarileri için OKA alanın bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	94.94	9.48	4.18	17.96	5.02	95.64	94.46
Att U-Net	93.37	12.20	7.73	35.45	6.91	95.01	92.12
Res U-Net	94.79	9.75	4.62	20.05	6.99	97.28	92.64
Att-Res U-Net	92.37	14.02	14.62	49.99	7.39	94.98	90.10
FractalSpiNet	94.90	9.57	4.21	18.55	4.94	95.15	94.83
Con-FractalSpiNet	94.99	9.43	4.24	17.53	4.94	95.63	94.53
Att-FractalSpiNet	94.70	9.92	4.71	23.20	5.02	95.51	94.10

FractalSpiNet modelleri ve diğer U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarileri için model eğitimleri sonunda tüm test veri seti için görselleştirme yapılarak DSC ve diğer tüm metrik değerleri hesaplanarak kaydedilmiştir. Bu aşamada, OKA/BOS aksiyel T2a MR test veri setinde bazı örnek görseller için hedef OKA alanın DSC skorları ile birlikte bölütleme sonuçları Şekil 5.2.’de verilmiştir. Test setinden seçilen örnek görüntülerin analizi yapılacak olursa tüm modellerin çok yüksek DSC puanlarıyla oldukça başarılı bölütleme sonuçları ürettiğini görülmektedir. Tüm modellerin yüksek performansına rağmen, önerilen Con-FractalSpiNet, FractalSpiNet ve temel U-Net mimarisi ile elde edilen DSC puanlarının daha yüksek olduğu görülmektedir.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con-FractalSpiNet	Att-FractalSpiNet
		 DSC:95.57	 DSC:94.34	 DSC:88.50	 DSC:92.02	 DSC:95.23	 DSC:94.63	 DSC:95.61
		 DSC:95.74	 DSC:96.69	 DSC:96.75	 DSC:93.38	 DSC:96.67	 DSC:96.69	 DSC:94.46
		 DSC:96.30	 DSC:94.85	 DSC:95.91	 DSC:95.38	 DSC:97.35	 DSC:96.53	 DSC:96.24
		 DSC:96.93	 DSC:95.02	 DSC:94.39	 DSC:90.73	 DSC:97.22	 DSC:97.61	 DSC:97.28
		 DSC:94.88	 DSC:95.21	 DSC:95.17	 DSC:91.72	 DSC:96.50	 DSC:95.21	 DSC:95.21
		 DSC:92.84	 DSC:95.08	 DSC:95.72	 DSC:92.93	 DSC:95.11	 DSC:95.44	 DSC:97.27




Şekil 5.2. Tüm model eğitimleri sonunda omurilik aksiyel OKA/BOS test kümesinden bazı örnek görseller için OKA bölütleme sonuçları ve DSC skorları

Deneyisel çalışmalarda, aynı eğitimler sonucunda farklı bölütleme sonuçları alarak ayrı ayrı değerlendirmeler yapılmıştır. Bu kapsamda eğitimler sonunda BOS olarak bilinen omurilik etrafını saran alanın bölütleme başarısı ayrıca değerlendirilmiştir. Tablo 5.7.'den detaylı bir analiz yapılacak olursa, FractalSpiNet sonuçlarının servikal omurilikteki BOS bölgesini bölütlemeye daha başarılı olduğu görülmektedir. Önerilen FractalSpiNet mimarisi kullanılarak elde edilen DSC puanları, tüm omurilikteki BOS bölgesi için %93.00 iken, U-Net %92.95, Att FractalSpiNet %92.82, Con-FractalSpiNet %92.76 ve Res U-Net %92.70 olmak üzere sırasıyla DSC skorları elde edilmiştir. Ayrıca, VOE için en yüksek skor FractalSpiNet modeli ile hesaplanırken, HD95 Att-FractalSpiNet ile ASD değeri Res U-Net modelinde ve RVD için ise Con-FractalSpiNet modeli ile daha başarılı sonuçlar elde edilmiştir. Mesafe tabanlı metriklerin sonuçlarının da önerilen FractalSpiNet mimarileri ile toplamda daha başarılı olduğu ve daha küçük mesafeler elde edebilme yeteneği doğrulanmaktadır. Yine genel anlamda en az başarılı sonuçlar dikkat modelleri olan Att-Res U-Net ve Att U-Net eğitimleri ile hesaplanırken, dikkat bağlantısının fractal mimari yapısıyla daha uyumlu çalıştığı Att-FractalSpiNet elde ettiği skorlardan görülmektedir.

Tablo 5.7. Omurilik aksiyel OKA/BOS alt veri kümesinde FractalSpiNet mimarileri ve diğer U-Net mimarileri için BOS alanın bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	92.95	12.93	6.95	8.73	6.62	93.49	92.76
Att U-Net	92.28	13.98	8.27	11.99	8.69	94.57	90.58
Res U-Net	92.70	13.37	7.15	7.21	6.74	92.02	93.80
Att-Res U-Net	91.93	14.61	14.87	27.97	7.70	92.70	91.64
FractalSpiNet	93.00	12.89	6.83	7.72	6.56	93.22	93.11
Con-FractalSpiNet	92.76	13.29	7.29	7.35	6.44	92.44	93.43
Att-FractalSpiNet	92.82	13.18	6.71	9.39	7.33	94.18	91.85

FractalSpiNet modelleri ve diğer U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarileri için OKA/BOS aksiyel T2a MR test veri setinde bazı örnek görseller için hedef BOS alanın DSC segmente skorları ile bölütleme sonuçları Şekil 5.3.'te verilmiştir. Test setinden seçilen örnek görüntülerin analizi yapılacak olursa tüm modellerin çok yüksek DSC puanlarıyla oldukça başarılı bölütleme sonuçları ürettiği görülmektedir. Tüm modellerin yüksek performansına rağmen, önerilen FractalSpiNet mimarisiyle elde edilen DSC puanlarının daha yüksek olduğu deneysel çalışmalar sonucunda elde edilmiştir.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con-FractalSpiNet	Att-FractalSpiNet
		 DSC: 95.35	 DSC: 95.78	 DSC: 89.56	 DSC: 95.35	 DSC: 95.21	 DSC: 95.52	 DSC: 96.81
		 DSC: 84.97	 DSC: 83.15	 DSC: 84.71	 DSC: 78.77	 DSC: 90.79	 DSC: 90.28	 DSC: 87.28
		 DSC: 97.51	 DSC: 96.79	 DSC: 96.72	 DSC: 97.34	 DSC: 97.79	 DSC: 97.27	 DSC: 96.71
		 DSC: 96.42	 DSC: 95.94	 DSC: 95.66	 DSC: 94.49	 DSC: 96.78	 DSC: 95.15	 DSC: 96.92
		 DSC: 94.42	 DSC: 96.31	 DSC: 93.90	 DSC: 94.44	 DSC: 95.20	 DSC: 94.70	 DSC: 95.52
		 DSC: 93.38	 DSC: 95.00	 DSC: 93.19	 DSC: 93.43	 DSC: 94.23	 DSC: 93.35	 DSC: 95.32










Şekil 5.3. Tüm model eğitimleri sonunda omurilik aksiyel OKA/BOS test kümesinden bazı örnek görseller için BOS bölütleme sonuçları ve DSC skorları

Tablo 5.8.'de servikal omurilikteki OKA ve BOS tüm alanın bölütleme sonuçları ile elde edilen sonuçlar anahtar metrik skorları ile birlikte verilmiştir. Burada, FractalSpiNet sonuçlarının servikal omurilikteki OKA ve BOS tüm alanın segmentlemede %96.54 skor ile daha başarılı olduğu görülmektedir. U-Net, Res U-Net, Con-FractalSpiNet, Att-FractalSpiNet, Att-Res U-Net ve Att U-Net modelleri için DSC puanları sırasıyla %96.49, %96.44, %96.39, %96.25, %95.85 ve %95.84 olarak hesaplanmıştır. Ayrıca, VOE ve RVD gibi hacimsel tabanlı metrikler için sırasıyla FractalSpiNet ve U-Net modelleri başarılı iken, HD95 ve ASD gibi mesafe tabanlı metriklerin sonuçlarının da önerilen FractalSpiNet ve Con-FractalSpiNet ile daha başarılı olduğu ve daha küçük mesafelerin elde edilmesinde oldukça başarılı olduğu kanıtlanmıştır. Ayrıca, temel hesaplama metriklerden olan PRE değeri için önerilen Con-FractalSpiNet mimarisinde en başarılı sonuçlar elde edilmiştir. Dikkat mekanizmasının fractal mimarisiyle uyumu, elde edilen yüksek DSC skorlarıyla net bir şekilde görülmektedir.

Tablo 5.8. Omurilik OKA/BOS aksiyel alt veri kümesinde FractalSpiNet mimarileri ve diğer tüm U-Net mimarileri için OKA ve BOS tüm alanın bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	96.49	6.72	1.67	4.63	4.05	96.85	96.27
Att U-Net	95.84	7.87	3.36	7.85	5.86	97.70	94.26
Res U-Net	96.44	6.81	1.95	4.23	4.16	96.51	96.52
Att-Res U-Net	95.85	7.86	8.64	20.76	5.35	96.99	94.94
FractalSpiNet	96.54	6.64	1.39	3.98	4.12	96.59	96.63
Con-FractalSpiNet	96.39	6.91	1.72	3.78	4.07	96.19	96.73
Att-FractalSpiNet	96.25	7.16	2.11	5.46	4.54	97.22	95.45

FractalSpiNet modelleri ve U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarileri için model eğitimleri sonunda tüm test kümesi için OKA ve BOS tüm alanın DSC skorları ile vbirlikte bölütleme sonuçları Şekil 5.4.'te verilmiştir. Burada, tüm modellerin yüksek performansına rağmen, önerilen FractalSpiNet mimarileriyle elde edilen DSC skorlarının yüksek olduğu görülmektedir.



MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con-FractalSpiNet	Att-FractalSpiNet
		 DSC:97.37	 DSC:96.73	 DSC:97.83	 DSC:98.05	 DSC:97.17	 DSC:97.06	 DSC:98.38
		 DSC:93.09	 DSC:91.64	 DSC:92.90	 DSC:87.01	 DSC:96.59	 DSC:95.97	 DSC:94.03
		 DSC:98.33	 DSC:97.52	 DSC:97.78	 DSC:98.55	 DSC:98.77	 DSC:98.33	 DSC:97.37
		 DSC:97.71	 DSC:96.99	 DSC:97.79	 DSC:95.53	 DSC:98.45	 DSC:96.97	 DSC:97.98
		 DSC:97.23	 DSC:97.84	 DSC:97.59	 DSC:97.35	 DSC:98.06	 DSC:97.80	 DSC:98.31
		 DSC:97.09	 DSC:97.59	 DSC:96.57	 DSC:97.49	 DSC:97.41	 DSC:96.75	 DSC:97.35

Şekil 5.4. Tüm model eğitimleri sonucunda omurilik aksiyel OKA/BOS test kümesinden bazı örnek görseller için OKA ve BOS tüm alanın bölütlemel sonuçları ve DSC skorları

5.5. Omurilik Aksiyel MS Alt Veri Kümesinde Elde Edilen Sonuçlar

Servikal omurilik verisetinden oluşturulan ikinci alt veri kümesi ile omurilik OKA bölütlenmesi ve MS lezyonlarının tespiti gerçekleştirilmiştir. İlk alt veri kümesinde OKA ve BOS alanı bölütlenmişken, bu alt veri kümesinde omurilik MS alanı biraz daha küçülerek işaretlenmiştir. Bu alt veri kümesinde toplam 87 MR taraması kullanılarak toplam 231 görüntü ve maskesi elde edilmiştir. Veri artırma teknikleri kullanılarak bu alt veri kümesi de 1080 olarak genişletilmiştir. Ayrıca, yine bu alt küme Tablo 5.9.'da görüldüğü gibi %80 eğitim ve %20 test olarak ikiye ayrılmıştır. Bu alt veri kümesinde bölütleme işlemi için temel U-Net mimarisi başta olmak üzere karma U-Net mimarilerinden Att U-Net, Res U-Net, Att-Res U-Net mimarileri ve önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarileri kullanılarak birçok deneysel çalışma gerçekleştirilmiştir.

Tablo 5.9. Omurilik aksiyel MS alt kümesinin detayları


	MR görüntüsü	Uzman Maskesi	Teknik detaylar	Boyut	Eğitim kümesi	Test kümesi
Omurilik Aksiyel MS			Akiyal MR T2a	128x128 .jpg	864 (%80)	216 (%20)

Bu alt veri kümesi için eğitim sonucunda temel U-Net mimarisi, Att U-Net, Res U-Net, Att-Res U-Net mimarileri ve önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarileri için toplam parametre sayıları birbirinden oldukça farklı değerlere sahiptir. Modellerin eğitimi için parametre sayısı, eğitim süresi, doğruluk ve IoU değerleri Tablo 5.10’da detaylı olarak verilmiştir.

Tablo 5.10. Omurilik aksiyel MS alt veri kümesinde model parametre sayısının 200 epok için model eğitim süresi, doğruluk ve IoU sonuçları

Omurilik Aksiyel MS	Parametre	Zaman (dk)	Doğruluk (%)	IoU(%)
U-Net	31,401,349	28:37	99.77	87.48
Att U-Net	37,333,513	35:19	99.77	87.52
Res U-Net	33,156,933	33:47	99.78	80.87
Att-Res U-Net	39,089,097	40:50	99.74	79.86
FractalSpiNet	109,922,693	91:18	99.78	89.21
Con-FractalSpiNet	53,369,029	60:05	99.78	86.98
Att-FractalSpiNet	115,854,857	99:52	99.78	82.89

Model eğitimleri aşamasında her bir epok için Şekil 5.5. (a, b, c,d)’de U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet için model eğitimleri sonucunda elde edilen eğitim kaybı, eğitim doğruluğu, doğrulama kaybı ve doğrulama doğruluğu grafikleri verilmiştir. Eğitim doğruluğu ve eğitim kaybı grafikleri için klasik bir seyir izlerken değerlendirme kaybı ve değerlendirme doğruluğu grafiklerinde test kümesinde Att U-Net ve Att-FractalSpiNet modelinde yaklaşık 10 epok ve 5 epok değerinde en yüksek pikler gözlemlenmiştir. Bu durum test verisinin değerlendirilme aşamasında modelin zorlandığı veya belki hata aldığı bir anı göstermektedir. Bu büyüklükte olmasa da diğer modellerde değerlendirme doğruluğu grafiğinde herbir modelde farklı epok değerlerinde pikler görmek mümkündür. Eğitim doğrulama grafiğinde ise yine Att-FractalSpiNet modelinde başlangıç epokunda ve yaklaşık 22 epok değerinde en yüksek pik değeri aldığı görülmektedir.



Şekil 5.5. Omurilik aksiyel MS alt veri kümesi için U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet model eğitimleri sonucunda elde edilen eğitim kaybı(a), eğitim doğruluğu(b), doğrulama kaybı(c) ve doğrulama doğruluğu(d) değerlerinin grafikleri (200 epok, batch size=8)


















Servikal omurilik boyunca OKA ve MS lezyonlarının bölütleme için önerilen FractalSpiNet modelleri ve U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarilerinin eğitimleri sonucunda metrikler için elde edilen sonuçları Tablo 5.11.'de gösterilmiştir. Burada, tüm metrik değerleri test veri setinde bulunan tüm görüntüler için ayrı ayrı hesaplanarak ortalama skor çıkarılmıştır. Omurilik alanı (OKA), MS lezyonları ve MS'siz omurilik alanı bölütleme alanları olarak belirlenmiştir. Bu nedenle model eğitimleri sonucunda bu üç bölütleme sonuçları ayrı ayrı hesaplanmıştır. OKA bölütlemesi için Tablo 5.11.'de model test kümesi için elde edilen tüm metriklerin skorları verilmiştir. Con-FractalSpiNet ve FractalSpiNet mimarileri ile sırasıyla %98.89, %98.88 sonuçları elde edilmiş olup en başarılı modeller olarak görülmektedir. Diğer taraftan Res U-Net, U-Net, Att-FractalSpiNet, Att U-Net, ve Att-Res U-Net modelleri için DSC puanları sırasıyla %98.67, %98.54, %98.41, %98.01 ve %97.90 olarak hesaplanmıştır. VOE ve RVD gibi hacimsel benzerlik değerlendirme metrikleri için FractalSpiNet ile %2.04 ve %0.97 skorları ile en başarılı mimari olurken, mesafe tabanlı HD95 ve ASD metriklerin sonuçları için en yüksek

skorlar sırasıyla FractalSpiNet ve Con-FractalSpiNet için 0.39 mm ve 1.09 mm olarak elde edilmiştir. Ayrıca, PRE değeri için yine Con-FractalSpiNet en yüksek değere sahipken, REC değeri için FractalSpiNet kullanılarak daha başarılı sonuçlar elde etmiştir.

Tablo 5.11. Omurilik aksiyel MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için OKA alanı bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	98.54	2.67	0.49	1.67	1.51	98.43	98.69
Att U-Net	98.01	3.64	1.36	3.90	2.71	98.80	97.33
Res U-Net	98.67	2.43	0.60	1.55	1.55	98.69	98.70
Att-Res U-Net	97.90	3.90	1.32	3.68	2.19	98.59	97.26
FractalSpiNet	98.88	2.04	0.39	1.38	0.97	98.84	98.94
Con-FractalSpiNet	98.89	2.05	5.12	1.09	1.18	98.62	99.21
Att-FractalSpiNet	98.41	2.84	0.80	2.73	1.57	98.75	98.11

Bu alt veri kümesi için, FractalSpiNet modelleri ve diğer U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarileri kullanılarak tüm test veri kümesi için OKA alanının bölütleme sonuçları DSC skorları ile birlikte Şekil 5.6.'da verilmiştir. Burada, tüm modellerin yüksek bölütleme performansına rağmen, önerilen FractalSpiNet mimarileriyle oldukça yüksek DSC skorlarına ulaşıldığı görülmektedir.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con-FractalSpiNet	Att-FractalSpiNet
		 DSC:98.17	 DSC:98.90	 DSC:99.28	 DSC:96.40	 DSC:100	 DSC:100	 DSC:98.91
		 DSC:99.41	 DSC:99.42	 DSC:99.41	 DSC:99.12	 DSC:100	 DSC:100	 DSC:100
		 DSC:99.66	 DSC:99.32	 DSC:98.98	 DSC:98.63	 DSC:100	 DSC:100	 DSC:100
		 DSC:96.97	 DSC:95.26	 DSC:98.26	 DSC:94.96	 DSC:98.26	 DSC:98.69	 DSC:97.00
		 DSC:99.34	 DSC:99.67	 DSC:99.67	 DSC:99.17	 DSC:100	 DSC:100	 DSC:99.02
		 DSC:97.85	 DSC:99.70	 DSC:98.78	 DSC:100	 DSC:100	 DSC:100	 DSC:100

Şekil 5.6. Tüm mimariler için omurilik aksiyel MS test kümesinden bazı görseller için OKA alanının bölütleme sonuçları ve DSC skorları











Servikal omurilik MS aksiyel alt veri kümesinde bölütleme alanı için MS lezyonlarının bölütleme başarısında elde edilen sonuçlar Tablo 5.12.' de verilmiştir. Burada, uzmanlar tarafından işaretlenmesi yapılan gerçek maske verileri ile model eğitimleri sonunda test setinden seçilen örnek maske görüntülerin piksel bazlı kıyaslanması yapıldığında, oldukça küçük piksel alana karşılık gelen MS lezyonlarının tespiti çok zorlu bir görev olmasına rağmen, MS lezyonlarının yüksek DSC skorlarıyla tespit edildiğini görülmektedir. çok yüksek DSC puanları model eğitimleri sonunda elde edilmiştir. Önerilen Con-FractalSpiNet ve FractalSpiNet mimarileri kullanılarak, omurilik MS lezyonlarını tespit etmede DSC için %91.48 ve %90.90 olarak oldukça yüksek skorlar başarılmıştır. Diğer taraftan, Res U-Net, Att-FractalSpiNet, U-Net, Att-Res U-Net ve Att U-Net mimarileri ile MS lezyonlarının tespit edilmesinde sırasıyla %88.87, %88.79, %86.00, %83.06 ve %75.34 DSC skorları başarılmıştır. Ayrıca, VOE için Con-FractalSpiNet modeli ile %12.92 hesaplanırken, RVD için FractalSpiNet mimarisi ile %9.62 skoru elde edilmiştir ve hacimsel olarak benzerlik metrik oranı en yüksek skorlar elde edilmiştir. HD95 Con-FractalSpiNet ile ASD değeri FractalSpiNet modelinde daha başarılı sonuçlar elde edilmiştir. Böylelikle hem hacimsel tabanlı metriklerin sonuçlarının hemde mesafe bazlı metriklerin sonuçlarının önerilen FractalSpiNet ve Con-FractalSpiNet mimarileri ile toplamda daha başarılı olduğu ve daha küçük mesafelerin hesaplanabilirliğinin yüksek olduğu tespit edilmiştir. PRE ve REC değerleri için ise en yüksek skorlar Con-FractalSpiNet mimarisi ile sırasıyla %92.27 ve %92.13 olarak elde edilmiştir. Yine genel anlamda en az başarılı performans sonuçları, dikkat tabanlı modeller olan Att U-Net ve Att-Res U-Net ile elde edilmiştir.

Tablo 5.12. Omurilik aksiyel MS alt veri kümesinde FractalSpiNet mimarileri ve diğer U-Net mimarileri için elde edilen MS lezyonlarının bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	86.00	20.83	11.55	28.23	13.50	83.73	90.50
Att U-Net	75.34	36.18	21.92	67.98	24.52	69.56	85.25
Res U-Net	88.87	17.20	9.83	31.28	11.29	90.24	89.33
Att-Res U-Net	83.06	25.58	14.28	47.47	15.37	85.11	83.04
FractalSpiNet	90.90	14.06	8.06	16.08	9.62	91.26	92.20
Con-FractalSpiNet	91.48	12.92	7.27	20.84	9.93	92.13	92.27
Att-FractalSpiNet	88.79	17.17	11.59	35.81	11.77	89.33	89.79

Bu alt veri kümesi için, MS lezyonlarının tespitinde FractalSpiNet modelleri ve diğer U-Net karma modelleri için test kümesindeki bazı örnek kesitlerde elde edilen sonuçlar DSC skorları ile birlikte Şekil 5.7.'de gösterilmiştir. Bu aşamada, modellerin yüksek performansının yanında, önerilen FractalSpiNet mimarileriyle elde edilen %100 örtüşme ile

gerçekleşmiş örnek lezyonların varlığı bölütleme sonuçlarından görülmektedir ve sonuçların başarılı olduğu doğrulanmaktadır.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con-FractalSpiNet	Att-FractalSpiNet
		 DSC:83.87	 DSC:86.67	 DSC:94.12	 DSC:70.97	 DSC:96.97	 DSC:96.97	 DSC:90.90
		 DSC:80.00	 DSC:93.33	 DSC:77.78	 DSC:60.00	 DSC:100	 DSC:100	 DSC:88.89
		 DSC:96.67	 DSC:81.48	 DSC:87.88	 DSC:93.54	 DSC:98.36	 DSC:100	 DSC:100
		 DSC:85.42	 DSC:86.67	 DSC:88.89	 DSC:80.00	 DSC:96.97	 DSC:98.95	 DSC:97.92
		 DSC:88.57	 DSC:66.67	 DSC:94.29	 DSC:82.67	 DSC:98.51	 DSC:98.55	 DSC:97.06
		 DSC:95.83	 DSC:86.05	 DSC:91.67	 DSC:91.67	 DSC:100	 DSC:100	 DSC:98.99

Şekil 5.7. Tüm model eğitimleri sonunda omurilik Aksiyel MS test verisetinden bazı örnek görseller için MS lezyonlarının DSC tahmin skorları













Bu alt veri kümesinde, MS lezyonu olmayan OKA bölgesi, veri setindeki görüntülerde uzmanlar tarafından işaretlenen iki etiketten biridir. Bu etiket servikal omurilikte MS lezyonu olmayan OKA bölgesini temsil etmektedir. Bu alan tespit edilerek, MS lezyonlarının oldukça küçük hacimlere sahip olması nedeniyle MS lezyonlarının tespitinde düşük skorlar elde edilmesi durumuna alternatif ikinci bir bölütleme ile sonuçların ikili çapraz-doğrulaması yapılmıştır. Tablo 5.13'te bu alan için elde edilen bölütleme sonuçları değerlendirildiğinde, Con-FractalSpiNet ve FractalSpiNet mimarileri %97.25 ve %97.17 DSC skorları ile en başarılı modeller olarak görülmektedir. Bu mimarileri Res U-Net, Att-FractalSpiNet ve U-Net mimarileri sırasıyla %96.64, %96.48, %96.18 DSC skorlarıyla takip etmektedir. Att-Res U-Net ve Att U-Net mimarileri ise %94.50 ve %94.42 DSC skorlarına sahip olmasına karşılık, kullanılan mimariler arasında en az başarılı olarak temsil edilmektedir. Con-FractalSpiNet mimarisi ile hacim bazlı değerlendirme metriği olarak kullanılan VOE ve RVD için %4.84 ve %2.57 ile en yüksek skorlar elde edilirken, yine mesafe bazlı HD95 ve ASD metrikleri için de sırasıyla 2.41 mm ve 3.20 mm skorları elde edilmiştir. Bu kesit alanı için, önerilen

FractalSpiNet yöntemlerinin tüm temel metrikler için bölütleme performansı açısından U-Net mimarisinden daha iyi performans gösterdiği sonucuna varılabilmektedir. Res U-Net, Att-FractalSpiNet, U-Net, Att-Res U-Net ve Att U-Net mimarileri, MS lezyonu olmayan omurilik bölgesinde sırasıyla DSC için sırasıyla %96,64, %96,48 %96,18, %94,50 ve %94,42 olmak üzere en yüksek puanlar elde edilmiştir. Önerilen FractalSpiNet mimarisini takiben, Res U-Net modeli MS lezyon olmayan bölütleme sonuçları omurilik bölgesi bölütleme işlemlerinden daha başarılıdır. Tüm bölütleme çalışması değerlendirildiğinde FractalSpiNet modelleri ile oldukça başarılı sonuçlar elde edildiği görülmüştür. Yine dikkat mekanizmasının eklendiği modeller kıyaslandığında, en başarılı Att-FractalSpiNet modelinin olduğu anlaşılmaktadır.

Tablo 5.13. Omurilik aksiyel MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için MS'siz omurilik alanının bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	96.18	6.75	3.03	4.89	3.66	97.11	95.43
Att U-Net	94.42	9.94	5.01	13.13	7.87	97.75	91.58
Res U-Net	96.64	6.00	2.90	4.34	3.20	96.72	96.75
Att-Res U-Net	94.50	9.77	4.93	8.32	4.57	95.46	93.79
FractalSpiNet	97.17	5.00	2.45	3.72	2.64	97.27	97.20
Con-FractalSpiNet	97.25	4.84	2.41	3.20	2.57	97.10	97.58
Att-FractalSpiNet	96.48	6.08	3.092	6.06	3.52	97.22	95.96

MS'siz OKA alanının bölütlenmesinde, FractalSpiNet modelleri ve U-Net mimarileri için deneysel çalışmalarda, tüm mimariler için aynı test verisine ait model çıktıları Şekil 5.8'de görüldüğü gibidir. Mimarilerinin sonuçları servikal omurilik alanı sınırları içinde MS lezyonu olmayan OKA bölgesinin bölütleme için de karşılaştırılmıştır. Hem MS alanının segmente edilmesi, hemde MS'siz alanın segmente edilmesi sayesinde ikili doğrulama ile MS lezyonları tespit edilebilmektedir. Bu sayede zorlu test verilerinde lezyonların konumlarının ve büyüklüklerini doğrulama imkanı oluşmaktadır. Şekil 5.8.'de görülebileceği gibi, test setinden seçilen örnek MR görüntülerinin analizi, bölütleme sonuçları birbirine yakın olsa da, önerilen Con-FractalSpiNet, FractalSpiNet ve Att-FractalSpiNet mimarilerinde daha yüksek DSC skorları görülmektedir.


MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con- FractalSpiNet	Att- FractalSpiNet
		 DSC:98.35	 DSC:99.59	 DSC:99.17	 DSC:95.55	 DSC:99.59	 DSC:99.59	 DSC:100
		 DSC:98.75	 DSC:99.08	 DSC:98.76	 DSC:97.83	 DSC:100	 DSC:100	 DSC:99.38
		 DSC:98.71	 DSC:94.65	 DSC:96.07	 DSC:97.41	 DSC:99.56	 DSC:100	 DSC:100
		 DSC:85.93	 DSC:89.04	 DSC:90.08	 DSC:81.08	 DSC:97.71	 DSC:97.01	 DSC:93.43
		 DSC:95.73	 DSC:93.28	 DSC:97.87	 DSC:93.04	 DSC:99.58	 DSC:99.58	 DSC:98.74
		 DSC:96.07	 DSC:94.69	 DSC:95.28	 DSC:96.61	 DSC:100	 DSC:100	 DSC:99.57

Şekil 5.8. Tüm derin öğrenme mimarileri için omurilik aksiyel MS test kümesinde bazı örnek kesitler için MS'siz omurilik alanın bölütlenmesi ve DSC skorları

5.6. Omurilik Sagittal MS Alt Veri Kümesi ile Elde Edilen Sonuçlar

Servikal omurilik verisetinde üçüncü alt veri kümesi sagittal düzlemde elde edilen görüntüler için oluşturulmuştur. Burada, sagittal düzlemde OKA ve MS lezyonlarının bölütleme çalışması gerçekleştirilmiştir. Sagittal MR görüntülerinde MS lezyonları belirlemek konumu ve polarite bozuklukları bakımından oldukça zorlu olabilmektedir. Ayrıca aksiyel çekimlerde tek bir MR taramasında, ortalama 27 veri elde edilebilirken, sagittal çekimlerde bu sayı oldukça az olmakta ve ortalama 8 veya 9 MR kesiti içermektedir. Bu bakımdan bu 8 kesitten tüm omurilik sınırları gören veri sayısı 1 veya 2 olarak değişkenlik gösterirken, bu kesitlerde de MS alanını belirlemek oldukça zor olmaktadır. Diğer taraftan belirlenen MS alanlarında sıklıkla polarite bozuklukları gözlenmektedir. U-Net mimarileri ile çalışmanın temelini oluşturan verisetinde maske oluşturulması işlemi bu aşamada oldukça zorlu olmakta ve bu olumsuzluklar işaretlenen MS lezyonu sayısını da oldukça azalmaktadır. Bu nedenle bu alt veri kümesinde 34 MR taraması kullanılarak toplam 54 görüntü ve maskeleri elde edilebilmiştir. Bu alt veri kümesinde, veri artırma teknikleri kullanılarak görüntü sayısı 530 olarak genişletilmiştir ve Şekil 5.14'te görüldüğü gibi %80 eğitim ve %20 test olarak ikiye ayrılmıştır.

Tablo 5.14. Omurilik sagital MS alt veri kümesini detayları

	MR görüntüsü	Uzman Maskesi	Teknik detaylar	Boyut	Eğitim kümesi	Test kümesi
Omurilik Sagital MS			Sagittal MR T2a	320x320 .jpg	(%80)	(%20)

Sagital düzlemdeki deneysel çalışmalarda, U-Net mimarisi, Att U-Net, Res U-Net, Att-Res U-Net mimarileri ve önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet mimarilerinin eğitim sonucunda farklı katman ve bağlantı yapılarına sahip olduğu için toplam parametre sayılarının Şekil 5.15.’teki gibi birbirinden oldukça farklı olduğu görülmüştür. Parametre sayısı ile eğitim süresi arasında doğru orantılı bir ilişki vardır ve Bu durum eğitim süresini etkileyen en önemli etkenlerdendir. Model eğitim süresini görüntü boyutunun da etkilediği aksiyel ve sagital düzlemdeki görüntülerin eğitim süreleri arasındaki farktan anlaşılmaktadır. Şöyleki, aksiyel verilerin 128x128 boyutlarında olmasına karşılık sagital veriler, 320x320 boyutlarına sahiptir ve piksel bazlı eğitim gerçekleştiren U-Net mimarilerinin eğitim sürelerini etkilediği çok net görülmektedir.


Tablo 5.15. Omurilik sagital MS alt veri kümesinde model parametre sayısının 200 epoch için model eğitim süresi, doğruluk ve IoU sonuçları

Omurilik MS Sagital T2a MR	Parametre	Zaman	Doğruluk (%)	IoU(%)
U-Net	31,401,349	1:07:21	99.61	90.44
Att U-Net	37,333,513	1:25:23	99.60	91.67
Res U-Net	33,156,933	1:23:41	96.61	92.18
Att-Res U-Net	39,089,097	1:40:16	98.90	71.14
FractalSpiNet	109,922,693	3:51:55	99.63	91.81
Con-FractalSpiNet	53,369,029	2:30:44	99.60	90.23
Att-FractalSpiNet	115,854,857	3:59:51	98.93	79.78

* *Fractal U-Net ve Att-Fractal U-Net modelleri için bilgisayar özellikleri nedeniyle batchsize 4 olarak alınarak hesaplanmıştır. Bu nedenle hesaplama süresi iki model için artmıştır.*

Bu alt veri kümesinde, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet, U-Net, Att U-Net, Res U-Net, Att-Res U-Net modellerinin eğitim aşamalarını değerlendirmek için her bir epok için hesaplanan doğrulama ve kayıp değerleri için eğitim sonunda Şekil 5.9’daki grafik elde edilmiştir. Bu grafik detaylı incelenecek olursa eğitim doğrulama değeri neredeyse tüm modeller için %98.9 ile %99.63 arasında sonlanmış olup başarılı bir eğitim aşaması olduğu görülmektedir. Eğitim kaybı grafiğinden modellerin genelleşme eğrileri izlenebilmektedir. Doğrulama doğruluğu grafiği incelenecek olursa modellerin test veri seti

üzerinde bazı modellerde ilk epok değerlerinde pikler gözlemlenirken yer yer diğer modeller içinde 200 epok süresince bazı pik görülmektedir. Bu grafik ile modelin test verisetinde bulunan bazı örnek setleri tahmin ederken zorlandığı bu yüzden piklerin elde edildiğini söylemek gerekmektedir. Doğrulama kaybı grafiği incelenecek olursa modelin test verisi üzerinde tahmin ettiği değerlerin gerçek değerlerden hangi aralıklarda saptığını veya tahmin ederken zorlandığı aşamaları göstermektedir. Doğrulama grafikleri için eğri zamanla artarak birbirine en yakın değerlere ulaşırken kayıp grafiklerinde bu seyir tam tersi yönde azalan eğim göstermektedir ve ulaşabileceği en düşük seviyelere kadar inmektedir.



Şekil 5.9. Omurilik sagital MS alt veri kümesi için U-Net, Att U-Net, Res U-Net, Att-Res U-Net, FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet model eğitimleri sonucunda elde edilen eğitim kaybı (a), eğitim doğruluğu (b), doğrulama kaybı (c) ve doğrulama doğruluğu (d) değerleri grafikleri (200 epok)

Sagital MS alt veri kümesinde omurilik, MS lezyonları ve MS'siz omurilik alanı bölütleme için hedef alanlar olarak belirlenmiştir. Servikal omurilik boyunca sagital omurilik ve omurilik MS lezyonlarının bölütleme için önerilen FractalSpiNet modelleri ve diğer U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarileri eğitimleri sonucunda elde edilen metrik bazında performans sonuçları Tablo 5.16.'da gösterilmiştir. Tabloda, Att-Res U-Net mimarisi ile MS lezyonlarının tespitinde en yüksek DSC skoru %97.06 olarak elde edilmiştir. Hemen ardından FractalSpiNet ile %96.16'lık DSC skoru ile ikinci en yüksek başarımla elde edilmiştir.

Dolayısıyla, bu diğer alt veri kümeleri ile yapılan deneysel analizlerde daha az başarılı olan model genel anlamda Att-Res U-Net mimarisi iken, sagittal MS verisetinde oldukça başarılı performans göstererek en yüksek değerlere ulaşmıştır. Eğitim aşamalarında model parametrelerinde ve hiperparametre değerlerinde hiçbir değişiklik yapılmadığı göz önünde tutulursa, kullanılan verisetinin değişimi ile bu skor elde edilmiştir. Diğer alt veri kümelerinde görüntüler 128x128 boyutlarında iken, sagittal MS veri kümesindeki görüntüleri 320x320 boyutlarında olması modelin hedef bölütlemen alanın büyümesi ile doğru orantılı olduğu yorumu yapılabilmektedir. Diğer taraftan Tablo 5.16’da hacimsel benzerlik metrikleri olan VOE ve RVD için en yüksek skorlar Att-Res U-Net ile %5.67 ve %2.13 olarak elde edilirken, mesafe bazlı değerlendirme metrikleri için de yine Att-Res U-Net mimarisi en yüksek skorları elde ederek 0.14 mm ve 0.43 mm olarak hesaplanmıştır. Ayrıca, ResNet gibi derin omurga ağları büyük ve karmaşık veri setlerinde başarılıdır. Ancak, daha küçük ve basit veri setleri için çok derin mimariler aşırı öğrenmeye neden olabilmektedir (He vd., 2016: 770). Özellikle yapılan bazı çalışmalarda küçük veri setlerinde çok karmaşık modellerin aşırı öğrenme riskine işaret edilmektedir(C. Zhang vd., 2021: 107),(Goodfellow, 2016).

Tablo 5.16. Omurilik sagittal MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için omurilik alanın bölütleme sonuçları

Eğitim sonuçları	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	95.96	7.62	7.10	9.86	3.18	95.14	96.92
Att U-Net	95.63	8.22	4.70	10.66	3.88	95.94	95.48
Res U-Net	96.07	7.46	7.53	16.08	2.89	96.18	96.06
Att-Res U-Net	97.06	5.67	1.44	4.29	2.13	96.66	97.50
FractalSpiNet	96.16	7.25	9.10	6.23	3.28	96.43	96.03
Con-FractalSpiNet	95.92	7.61	4.14	8.59	3.47	94.94	97.13
Att-FractalSpiNet	95.98	7.60	3.82	7.72	3.66	96.32	95.78

FractalSpiNet ve U-Net, Att U-Net, Res U-Net ve Att-Res U-Net mimarileri için omurilik MS Sagittal T2a MR test veri setinde bazı örnek görseller için hedef omurilik alanın bölütleme sonuçları Şekil 5.10.’da verilmiştir. Tüm modeller yüksek performans gösterirken, özellikle önerilen Att-Res U-Net ve FractalSpiNet mimarisiyle elde edilen DSC skorlarının daha yüksek olduğu deneysel çalışmalar sonucunda görülmektedir.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con-FractalSpiNet	Att-FractalSpiNet
		 DSC:95.66	 DSC:95.99	 DSC:95.63	 DSC:95.42	 DSC:95.25	 DSC:96.04	 DSC:95.83
		 DSC:95.21	 DSC:95.30	 DSC:94.95	 DSC:96.57	 DSC:95.57	 DSC:93.82	 DSC:94.70
		 DSC:97.06	 DSC:97.64	 DSC:96.88	 DSC:98.63	 DSC:97.91	 DSC:97.77	 DSC:97.49
		 DSC:97.26	 DSC:97.64	 DSC:97.60	 DSC:97.86	 DSC:97.25	 DSC:97.16	 DSC:97.08
		 DSC:97.89	 DSC:97.67	 DSC:97.30	 DSC:98.39	 DSC:97.41	 DSC:97.68	 DSC:97.04
		 DSC:98.40	 DSC:98.25	 DSC:98.77	 DSC:98.51	 DSC:98.24	 DSC:99.40	 DSC:98.10

Şekil 5.10. Tüm mimariler için omurilik sagittal MS test kümesindeki bazı örnek kesitler için tüm omurilik alanın bölütlenmesi ve başarılan DSC skorları




















Servikal omurilik MS sagittal alt veri kümesinde, aksiyel verisetinde olduğu gibi MS lezyonları oldukça küçük hacimlere sahiptir. Sagittal alt veri kümesi için detaylı analizler yapılmış olmakla beraber, aksiyel verilerden farklı olarak MS lezyonlarını MR verisinde işaretlemek oldukça güçlü bir aşama olmuştur. MR görüntüsünde MS lezyonlarının sınırlarının keskin bir şekilde belli olmaması polarite bozuluklarına sahip olması eğitim sonunda elde edilen başarıyı oldukça düşürdüğü gözlemlenmiştir. Literatürde de yapılan bazı çalışmalarda, MS verilerinin analizi için sıklıkla aksiyel düzlem kesitlerine başvurulduğu ve sagittal düzlemde lezyonların tespitinde yaşanan güçlükler ifade edilmiştir (Alcaide-Leon vd., 2016: 970; Galler vd., 2016: 963). Tablo 5.17’de test setinden seçilen örnek görüntülerin piksel bazlı kıyaslanması yapıldığında MS lezyonlarının başarısının DSC skoru ile, bazı modellerde %50 üzerinde, bazı modellerde ise altında edildiği görülmektedir. Oldukça küçük piksel alana karşılık gelen MS lezyonlarının sagittal düzlemde tespiti, aksiyel düzleme göre oldukça zorlu bir görev olarak ifade edilebilmektedir. Burada, Con-FractalSpiNet mimarisi MS lezyonlarını tespit etmede en yüksek DSC puanına ulaşarak %56.25 olarak hesaplanmıştır. Yine Att-Res U-Net ve U-Net mimarileri sırasıyla %55.61 ve %53.04 ile yüzde ellinin üzerinde bölütleme başarıyı elde edilmiştir. Hacimsel benzerlik metriği olan

VOE için en yüksek değeri DSC skoru ile paralel olarak Con-FractalSpiNet mimarisi ile %56.58 olarak hesaplanırken, diğer hacimsel metrik olan RVD için en yüksek skor Att-FractalSpiNet ile %34.82 olarak elde edilmiştir. Ayrıca REC ve PRE gibi diğer önemli metrikler için de yine Con-FractalSpiNet mimarisi servikal omurilik MS lezyonlarının bölütlemeye daha iyi performansa sahiptir. Att U-Net modeli ile yine en az başarılı sonuçlar elde edilmiştir.

Tablo 5.17. Omurilik sagittal MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için MS lezyonlarının bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	RVD (%)	REC (%)	PRE (%)
U-Net	53.04	60.24	47.87	59.29	51.83
Att U-Net	41.32	71.98	75.05	53.43	36.41
Res U-Net	42.19	69.67	43.35	43.67	45.47
Att-Res U-Net	55.61	58.53	34.90	59.45	55.53
FractalSpiNet	46.35	67.20	35.29	48.58	47.40
Con-FractalSpiNet	56.25	56.58	43.59	61.04	55.98
Att-FractalSpiNet	43.94	68.63	34.82	44.30	47.08

Bu alt veri kümesinde, FractalSpiNet ve diğer tüm U-Net mimarileri için test veri kümesinde bazı örnek kesitler için MS lezyonlarının DSC ile skorları bölütleme sonuçları Şekil 5.11.'de verilmiştir. Bu aşamada seçilen örnek görüntülerin analizi yapılacak olursa, tüm modellerde diğer alt veri kümeleri için elde edilen yüksek skorlar elde edilmediği görülmektedir. Con-FractalSpiNet ve Att-Res U-Net mimarileri ile diğer mimarilere göre daha başarılı sonuçlar elde edildiği görülmektedir. Bu alt veri kümesinde, MS lezyonlarının net bir polarite farkına sahip olmaması ve çok küçük temsil alanına sahip MS lezyonları nedeniyle elde edilen sonuçlar diğer verisetlerine oranla düşük kalmıştır. Özellikle Res U-Net modelinde bazı verilerde hiç lezyon tespit edemediği MR test görüntüleri olmuştur. Diğer taraftan aktif bir lezyon alanı olmasına rağmen, modellerin birden fazla lezyon alanı tespit etmesinin sebebi MR görüntüsünde omurilik sınırları içerisinde işaretlenen MS poritesine benzer polarite alanlarının olmasıdır.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con- FractalSpiNet	Att- FractalSpiNet
		 DSC:50.77	 DSC:00.00	 DSC:29.63	 DSC:60.00	 DSC:62.31	 DSC:48.84	 DSC:39.06
		 DSC:60.57	 DSC:43.44	 DSC:03.42	 DSC:45.96	 DSC:61.62	 DSC:64.74	 DSC:61.80
		 DSC:48.37	 DSC:43.00	 DSC:61.58	 DSC:79.72	 DSC:64.02	 DSC:68.51	 DSC:16.90
		 DSC:62.11	 DSC:64.30	 DSC:00.00	 DSC:59.29	 DSC:64.69	 DSC:78.29	 DSC:20.28
		 DSC:38.20	 DSC:29.37	 DSC:00.00	 DSC:53.80	 DSC:61.69	 DSC:54.78	 DSC:15.29
		 DSC:68.33	 DSC:66.37	 DSC:72.28	 DSC:83.70	 DSC:72.64	 DSC:87.70	 DSC:97.04



































Şekil 5.11. Tüm mimariler için omurilik sagittal MS test kümesindeki bazı örnek görüntüler için MS lezyonlarının bölütleme sonuçları ve DSC skorları

Sagittal MS alt veri kümesinde MS lezyonu olmayan omurilik bölgesinin bölütleme işlemlerine ait sonuçlar Tablo 5.18.'de sunulmuştur. Bu alanın bölütleme sagittal verilerde daha önemli hale gelmiştir. Çünkü sagittal verilerde MS lezyonlarının tespitinde oldukça düşük skorlar elde edilmesi, daha büyük hacme sahip olan MS'siz omurilik alanının tespit edilmesi ile ikili doğrulamayı zorunlu hale getirmektedir. Burada, tüm omurilik alanın bölütleme sonuçlarına benzer sonuçlar elde edilmiş olup, en yüksek DSC skoru yine Att-Res U-Net mimarisi ile %95.16 olarak hesaplanmıştır. Hemen ardından FractalSpiNet ile %94.10 DSC skoru elde edilmiştir. Diğer mimarilerin skorları birbirlerine çok yakın sonuçlara sahiptir. Hacimsel örtüşmeyi ifade eden VOE ve RVD değeri yine en yüksek DSC skoruna sahip olan Att-Res U-Net modeli ile %9.12 ve %2.64 olarak gerçekleşmiştir. Mesafe bazlı metriklerde ise yine Att-Res U-Net modeli en yüksek skorlara sahip model olarak HD95 için 0.48 mm ve ASD için 0.72 mm olarak en hassas değerlere ulaşmıştır.

Tablo 5.18. Omurilik sagital MS alt veri kümesinde FractalSpiNet mimarileri ve U-Net mimarileri için MS'siz omurilik alanın bölütleme sonuçları

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	93.88	11.29	10.16	13.65	4.22	93.13	94.80
Att U-Net	93.40	12.00	9.20	13.77	5.09	93.06	94.06
Res U-Net	93.78	11.49	11.33	21.29	5.08	94.73	93.06
Att-Res U-Net	95.16	9.12	4.83	7.19	2.64	94.85	95.53
FractalSpiNet	94.10	10.86	13.13	11.39	5.12	95.03	93.45
Con-FractalSpiNet	93.76	11.36	7.85	12.78	5.28	93.06	94.84
Att-FractalSpiNet	93.83	11.36	7.23	13.35	5.97	95.11	92.88

FractalSpiNet modelleri ve diğer tüm U-Net mimarileri için test kümesindeki bazı kesitler için bölütleme sonuçları Şekil 5.12'de sunulmuştur. Burada, örnek görseller incelendiğinde bölütleme başarımlarının oldukça değişkenlik gösterdiği görülmektedir. Örneğin ilk görselde en yüksek DSC skoru Att-FractalSpiNet ile %96.81 olarak alınırken, ikinci ve üçüncü kesit için Att-Res U-Net modelleri ile %95.43 ve %97.73 DSC skorları başarılmıştır. Diğer taraftan dördüncü kesit için %96.74 ile Att U-Net, beşinci kesit için %96.84 ile FractalSpiNet ve altıncı kesit için ise %99.08 ile Con-FractalSpiNet modellerinde en yüksek DSC skorları elde edilmiştir. MS alanında daha fazla piksel alanı ile temsil edilen MS'siz omurilik alanı için, elde edilen skorlar oldukça yüksek olmasını sağlamaktadır. Bu nedenle MS alanlarının başarılı olarak tespit edildiği sonucu çok doğru olmamakla beraber MS lezyonlarının konum olarak doğruluğu için bir kriter olmasına karşılık hacimsel olarak çok başarılı sonuçlar vermemektedir. Bu bağlamda sagital MR verileri ile MS lezyonlarının daha yüksek başarımlar ile tespit edilmesi için MR verilerinin oldukça kaliteli teknik özelliklere sahip olması gerektiği analizi çıkmaktadır. MR verilerinde MS lezyonlarının net bir şekilde izlenebilirliği U-Net modellerinin başarısını doğrudan etkilen en önemli teknik özellik olduğu ve bu durumun sagital düzlemde MS lezyonlarının tespit edilmesinin zorlu bir görev olarak geçerliliğini koruduğu uçtan uca yapılan çalışmalar neticesinde ifade edilebilmektedir.

MR Görüntüsü	Uzman Maskesi	U-Net	Att U-Net	Res U-Net	Att-Res U-Net	FractalSpiNet	Con- FractalSpiNet	Att- FractalSpiNet
		 DSC:94.89	 DSC:93.89	 DSC:94.11	 DSC:94.28	 DSC:94.42	 DSC:93.80	 DSC:96.81
		 DSC:94.20	 DSC:93.91	 DSC:92.56	 DSC:95.43	 DSC:94.84	 DSC:92.82	 DSC:93.44
		 DSC:94.49	 DSC:96.30	 DSC:95.18	 DSC:97.73	 DSC:96.48	 DSC:96.06	 DSC:94.95
		 DSC:96.00	 DSC:96.74	 DSC:95.51	 DSC:96.73	 DSC:96.56	 DSC:96.27	 DSC:95.50
		 DSC:92.84	 DSC:92.58	 DSC:94.77	 DSC:96.74	 DSC:96.84	 DSC:94.61	 DSC:94.40
		 DSC:97.33	 DSC:97.76	 DSC:97.93	 DSC:98.38	 DSC:98.03	 DSC:99.08	 DSC:97.50

Şekil 5.12. Tüm mimariler için omurilik sagittal MS test kümesindeki bazı örnek kesitler için MS'siz omurilik alanın bölütleme sonuçları ve DSC skorları


6. TARTIŞMA

Bu tez çalışmasında, omurilik ve omurilik bölgesinde bulunan MS lezyonlarının önerilen U-Net tabanlı derin öğrenme mimarileri ile tespiti ve bölütlenmesi gerçekleştirilmiştir. Deneysel analizler sonucunda elde edilen sonuçlar detaylı olarak incelendiğinde, servikal omurilik T2 MR görüntüleri kullanılarak oluşturulan omurilik aksiyel OKA/BOS, omurilik aksiyel MS ve omurilik sagittal MS veriseti alt grupları ile önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarileri ve U-Net, Att U-Net, Res U-Net ve Att-Res U-Net gibi rekabetçi diğer modeller kullanılarak elde edilen sonuçlar ayrı ayrı değerlendirilmiştir. Diğer taraftan, model ayarlamaları için ortak parametreler seçilerek modellerin eşit bir yaklaşımla değerlendirilmesi sağlanmıştır. Modeller için tercih edilen parametreler batch boyutu 8, öğrenme oranı 0.001, aktivasyon fonksiyonu ReLU, kayıp fonksiyonu binary cross entropy, optimizasyon fonksiyonu sigmoid, optimizasyon algoritması adam ve dropout değeri 0.5 olarak 200 epok değerleri kullanılarak tüm alt veri kümeleri için eğitimler gerçekleştirilmiştir. Tüm eğitimler sonunda model başarılarını ölçmek için literatürde sıklıkla kullanılan piksel örtüşme temeline dayanan DSC, PRE ve REC değerleri kullanılırken diğer taraftan hacimsel bazlı olarak VOE, RVD ve mesafe bazlı olarak ASD ve HD95 metrikleri değerlendirme metrikleri olarak kullanılmıştır. Farklı yaklaşım temellerine sahip metriklerin kullanılması modelleri çok yönlü analiz edilmesine olanak sağlamaktadır.

Omurilik yapısı itibarıyla belirli bir geometrik şekle sahip olmamakla beraber omur yapısına göre de kıvrımlı bir şekle sahiptir. Bu nedenle bölgenin bölütlenmesi sınırlarının belirlenmesi oldukça zorlu bir konu olarak ortaya çıkmaktadır. Bu alanda tespit edilmeye çalışılan lezyonlar konum, boyut ve şekil bakımından oldukça heterojen bir yapıya sahiptir. Lezyon vokselleri orijinal MR verilerinde tüm omurilik hacmine oranla çok az bir alan ile temsil edilmektedir. Özellikle sagittal düzlemdeki verilerde tüm omurilik alanı boyunca aksiyel düzlemdeki verilere oranla çok daha küçük hacimlere sahip olabilmektedir. Lezyon yoğunluklarının gri madde yoğunluklarına ve diğer bazı dokusal yapılara benzerlik göstermesi, maskeleye yaparken ve eğitim sırasında olumsuz sonuç olarak karşımıza çıkmaktadır.

Omurilik bölütleme ve MS lezyonlarının tespiti için yürütülen deneysel analizlerde, başarılı skorların yanı sıra test veri seti değerlendirildiğinde modellerin omurilik sınırlarının tam olarak belirleyemediği, taşma veya daha az alanın tahmin edildiği örnek veriler Şekil 6.1.(a)'da verilmiştir. Bazı piksel eklentilerinin olduğu görülmesine rağmen bu durum omurilik sınırlarını yine de yüksek başarılar ile tespit edildiği görülmektedir. İkinci hedef


bölütlenme alanı olan beyin omurilik sınırları için modellerin başarıları test edilmiştir. Başarılı bir sonuçlar sergileyen modellerin test verisetleri incelendiğinde bazı verilerde %90'ın altında piksel örtüşmesi olan bazı verilere rastlanmıştır. Bu verilere örnek görseller Şekil 6.1.(b)'de verilmiştir. Üçüncü bölütlenme alanı omurilik ve beyin omurilik alanlarının birlikte temsil edildiği tüm alan olarak belirlenmiştir. Bu görseller incelendiği Şekil 6.1.(c)'de görüleceği gibi başarısız sonuçlarda bile, önerilen yöntemlerin oldukça yüksek DSC skorlarına sahip olduğu görülmektedir.



Şekil 6.1. Önerilen FractalSpiNet mimarileri ve modeller kullanılarak omurilik alanının bölütlenmesi (a), beyin omurilik sıvısı alanının bölütlenmesi (b), omurilik ve beyin omurilik sıvısı tüm alanın bölütlenmesi (c) için nispeten düşük başarıma sahip sonuçlar

Omurilik aksiyel MS alt veri kümesinde, test kümesinde yapılan değerlendirmeler sonucunda gözlemlenen bazı bölütlenme hatalarını gösteren örnek veriler Şekil 6.2.(a)'da gösterilmektedir. Eksik piksel veya fazla piksel olarak kendini gösteren örtüşme hataları elde edilen metrik değerlerini doğrudan etkileyerek model başarı skorlarını değiştirmektedir. Diğer taraftan, MS lezyonlarının çok küçük piksellerle ifade edildiği ve belirli bir geometrik şekle

sahip olmadığı göz önüne alındığında, önerilen Con-FractalSpiNet ve FractalSpiNet mimarilerinin oldukça başarılı bölütleme gerçekleştirdiği ve dikkate değer sonuçlar elde ettiği söylenebilir. Ancak, yine de MS lezyonlarının tespitinde nispeten daha düşük başarıma sahip bazı sonuçlar ise Şekil 6.2.(b)'de verilmiştir.




Şekil 6.2. Önerilen FractalSpiNet mimarileri ve diğer tüm modeller için omurilik aksiyel MS alt veri kümesinde tüm omurilik alanının bölütlenmesi (a), omurilik MS lezyonlarının bölütlenmesi (b), MS lezyonları olmayan omurilik alanının bölütlenmesi (c) için daha düşük başarıma sahip kesitler

MS lezyonlarının hacimsel olarak tam belirlenemediği eksik veya dağınık bir bölgenin tahmin edildiği sonuçlardan görülmektedir. Nitekim eğitimler sonunda MR görüntüsünün çekim kalitesinin, MS lezyonlarına benzer polaritelere sahip alanların olması MS lezyonlarının sınırlarının net bir şekilde belirli olmaması durumlarında etiket işlemlerinde hata olasılıklarını artırmakta çıkarımı yapılabilmektedir. Aslında MR görüntüsünde MS lezyonlarına benzer polaritelere sahip alanlar başarıyı düşürmekte ve işlem adımlarının en başında maske verisini (temel gerçek) hazırlamayı oldukça zorlaştırmaktadır. Bu nedenle, önerilen çalışmanın yüksek kaliteli net MR kesitlerinde MS lezyonlarının tespitine katkı

sağlaması oldukça olası iken MR görüntüsü ve gerçek maske verisi arasındaki hatalı etiketleme işlemleri model başarılarını oldukça etkilemektedir. Diğer bölütleme alanı olan MS'siz omurilik alanının tespit edilmesi için yine tüm modeller ile eğitimler gerçekleştirilmiştir. MS'siz omurilik alanı bölütleme çalışmasına dahil edilmesinin en büyük sebebi MS lezyonları bölütleme ile birlikte ikili doğrulama sağlamaktır. Test verisetinde oldukça yüksek piksel örtüşmeleri gözlemlenirken, Şekil 6.2.(c)'de verilen bazı örnek görüntülerde daha az veya daha çok piksel eşleşmeleri gerçekleşmiştir.

Omurilik sagittal MS alt veri kümesinde önerilen mimariler kullanılarak, omurilik alanının bölütlenmesinde, MS lezyonlarının tespitinde ve MS olmadan omurilik alanının bölütlenmesinde daha düşük başarıma sahip sonuçlara örnekler sırasıyla Şekil 6.3(a), Şekil 6.3(b) ve Şekil 6.3(c)'de gösterilmiştir. Att-Res U-Net mimarisinin bu alt veri kümesi ile uyumu oldukça dikkat çeken bir detay olmuştur. Çünkü diğer iki alt veri kümesi ile yapılan sonuçlar değerlendirildiğinde, az başarılı skorları elde eden modellerden biri iken, sagittal MS alt veri kümesi ile en başarılı DSC skorlarını elde eden mimarilerden biri olmuştur. Burada, aksiyel düzlemdeki alt veri kümeleri 128x128 iken sagittal düzlemdeki görüntü boyutları 320x320 olması ilk belirgin özellik olarak değerlendirilmektedir. Nitekim çalışma alanının büyümesi modelin başarısına olan katkısını olumlu etkilemiş olabileceği görüşü oldukça yüksek bir olasılık olarak değerlendirilebilmektedir. Başarı farkını etkileyen en önemli etkenlerden olan veri sayısı olduğu düşünülürse sagittal veri kümesinin daha kapsamlı bir hale getirilerek, artırılması veri çeşitliliğine katkı sunması ve model başarılarını olumlu yönde etkilemesi beklenmektedir. Diğer taraftan, sagittal düzlemdeki verilerde MS lezyon başarıları oldukça düşük olması yüksek başarımlar için motivasyon kaynağı iken, sagittal MR verilerinde gözlemlenen polarite bozuklukları bu başarıyı düşüren en önemli etkindir. Sagittal verilerde net MS lezyonları gözlemlenirken diğer taraftan net olmayan pikseller ile temsil edilen ve bu yüzden maskeleye işlemlerinin oldukça zorlu olduğu MR verilerinde bulunmaktadır. MR verilerinin kalitesinin artırılması MR çekim kalınlığının düşürülmesi verisetinin çeşitlenmesi ve sayısının artmasına oldukça olumlu katkı sunacaktır. Test verisetinde bulunan örnek veriler incelendiği bazı modellerde MS verileri hiç piksel örtüşmesi gerçekleşmeyen veriler bulunurken daha az veya çok hatalı veriler ile karşılaşmak mümkündür.



Şekil 6.3. Önerilen FractalSpiNet mimarileri ve diğer tüm modeller için sagittal düzlem alt veri kümesinde tüm omurilik alanının bölütlenmesinde (a), omurilik MS lezyonlarının bölütlenmesinde (b), MS lezyonları olmayan omurilik alanının bölütlenmesinde (c) daha düşük başarılı sonuçlar


Aksiyel omurilik alanı içerisinde bulunan gri madde bölgesi yine MS alanlarının segmente edilmesi gibi zorlu bir çalışma konusu olarak literatürde geçmektedir. Tez çalışması kapsamında önerilen yöntemlerin performansı, aynı zamanda, açık bir veriseti olarak sunulan SCGMSC verisetindeki görüntüler ile de değerlendirilmiştir. Bu veri seti, dört farklı siteden alınan omurilik görüntülerinden oluşmaktadır. Deneysel analizler için, bu verisetinden 328 eğitim (~%80) ve 83 test (~%20) seti dahil olmak üzere toplam 411 MR görüntüsü ve gerçek maske seçilmiştir. Veriseti yine 128x128 olarak hazırlanmış olup veri artırma teknikleri uygulanmadan mevcut sayı adedince eğitimler gerçekleştirilmiştir. Ayrıca, önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarisinin bu verisetindeki performansı, U-Net mimarisi ve türevleri olan Att U-Net, Res U-Net ve Att-Res U-Net modelleriyle karşılaştırılmıştır ve elde edilen sonuçlar Tablo 6.1’de sunulmuştur. Model

eğitimleri sonunda gri bölgenin bölütlemesinde, en yüksek DSC skoru %83.20 ile U-Net mimarisi ile elde edilmiş olup, hemen ardından % 83.05 DSC skoru ile FractalSpiNet elde etmiştir. Önerilen FractalSpiNet ve U-Net modellerinin sonuçlarının diğer modellere göre oldukça yakın ve daha başarılı olduğu sonucuna varılabilmektedir. Con-FractalSpiNet ve Att U-Net mimarileri ile %81.96 ve %80.40 DSC skoru olarak başarımlar elde edilmiştir.

Tablo 6.1. Omurilikte GM bölütlemesi için SCGMSC verisetinde FractalSpiNet mimarileri ve U-Net mimarilerinin sonuçlarının değerlendirilmesi

Derin Öğrenme Mimarileri	DSC (%)	VOE (%)	HD95 [mm]	ASD [mm]	RVD (%)	REC (%)	PRE (%)
U-Net	83.20	28.42	1.33	4.84	9.09	85.49	81.35
Att U-Net	80.40	32.36	1.55	5.83	8.92	79.38	81.98
Res U-Net	79.24	33.87	1.72	5.59	10.14	76.61	82.65
Att-Res U-Net	74.79	39.65	4.25	10.78	14.41	78.11	72.47
FractalSpiNet	83.05	28.68	1.39	4.84	10.55	86.28	80.42
Con-FractalSpiNet	81.96	30.20	1.35	4.45	9.79	79.28	85.46
Att-FractalSpiNet	75.75	37.81	6.62	27.74	22.13	77.36	76.31

SCGMSC verisetinde test kümesinde başarılı piksel örtüşmelerinin olduğu veri örnekler Şekil 6.4.'de verilmiştir. Görüntülerden anlaşılacağı üzere, U-Net ve FractalSpiNet ile oldukça yüksek bölütleme sonuçları elde edilirken, diğer modeller ile %83'ün altında DSC skorları elde edilmiştir.



Şekil 6.4. Önerilen FractalSpiNet mimarileri ve diğer tüm modellerin SCGMSC verisetinde omurilik GM bölütleme sonuçları

Omurilik bölütleme için bazı kamuya açık veri kümeleri olmasına rağmen, servikal omurilik bölgesini ve bu bölgedeki MS lezyonlarını özel olarak içeren kamuya açık bir veri kümesi bulunmamaktadır. Bu nedenle, bu çalışmanın sonuçlarını birçok parametrede diğer son teknoloji yaklaşımlarla karşılaştırmak genel anlamda mümkün değildir. Ayrıca, çalışmalarda kullanılan farklı yöntemler eşit karşılaştırmayı daha da zorlaştırmaktadır. Ayrıca, birçok çalışmada değerlendirme metrikleri olarak tercih edilen

temel performans ölçütleri de birbirinden çok farklıdır. Bununla birlikte, genel literatür taraması yapıldığında çalışmamıza yakın ölçekte veri seti kullanan ve yöntemlerinde DSC skoru sonuçlarını veren benzer bazı çalışmalarla karşılaştırılması Tablo 6.2.'de verilmiştir. Servikal omurilik bölgesinde çalışmanın zorlukları göz önüne alındığında, bu çalışmada önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarilerinin çok başarılı performans sonuçları elde ettiği görülebilmektedir.

Daha önce önerilen omurilik bölütleme çalışmalarının çoğu, bu tez çalışması da dahil olmak üzere orijinal veri setini kullanmıştır. Ancak Bedard ve arkadaşları (Bédard ve Cohen-Adad, 2022: 1031253) , kamuya açık bir veri seti olan omurga veriseti kullanmıştır. Öte yandan, en son çalışmalar çoğunlukla omurilik bölütleme gerçekleştirmiştir ve omurilikte MS lezyonu tespiti üzerine birkaç çalışma da vardır. Bu çalışmalar arasında omurilik alanın segmente edilmesi ile veriler sunan çalışmalar De Leener ve arkadaşları (De Leener vd., 2014: 528) ve (De Leener vd., 2015: 1705), Zhuo ve arkadaşları (Zhuo vd., 2022: e210292), Prados ve arkadaşları (F. Prados vd., 2016: 36151), X. Zhang ve arkadaşları (Xiaoran Zhang vd., 2021: 104345) yaptıkları çalışmalar ile elde edilen DSC skorları Tablo 6.2.'de verilmiştir. Omurilik MS lezyonlarını veya diğer tümör vb. yapıların tespit etmek için yapılan çalışmalar ise Gros ve arkadaşları (Gros vd., 2019: 901), Lemay ve arkadaşları (Lemay vd., 2021: 102766), Zhuo ve arkadaşları (Zhuo vd., 2022: e210292) olarak literatürde yer almaktadır. Bu tez çalışmasında orijinal veri setinde önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet mimarilerinin diğer yöntemlerle kıyaslayarak sonuçların analizleri yapılmıştır. Nitekim 3 farklı alt veri kümesi ile deneysel çalışmalar yapılmıştır. Omurilik OKA/BOS aksiyel T2a MR veri seti ile omurilik bölütleme için elde edilen sonuçlar FractalSpiNet %94.90, Con-FractalSpiNet %94.99 ve Att-FractalSpiNet %94.70 tespit edilmiştir. Yine aynı veri seti ile beyin omurilik sıvısı bölütleme sonuçları FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet için sırasıyla %92.99, %92.76 ve %92.82 olarak tespit edilmiştir. Son olarak omurilik ve beyin omurilik sıvısı alanlarının toplamı için alınan bölütleme sonuçları için elde edilen DSC skorları FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet için sırasıyla %96.54, %96.39 ve %96.25 olarak hesaplanmıştır. Omurilik MS aksiyel T2a MR veri seti ile omurilik bölütleme sonuçları FractalSpiNet %98.88, Con-FractalSpiNet %98.89 ve Att-FractalSpiNet %98.41 olarak elde edilmiş olup omurilik MS sagittal T2a MR veri setinde ise bu sonuçlar FractalSpiNet %96.16, Con-FractalSpiNet %95.92 ve Att-FractalSpiNet %95.98 olarak tespit edilmiştir. Diğer yapılan çalışmalar ile kıyaslandığında omurilik bölütleme ile elde edilen en yüksek DSC skoru %96 olarak tespit edilmiştir. Omurilik aksiyel MS verisi ile MS lezyonları

için alınan bölütleme sonuçları FractalSpiNet %90.90, Con-FractalSpiNet %91.48 ve Att-FractalSpiNet %88.79 olarak oldukça rekabetçi sonuçlar elde edilirken omurilik sagittal MS alt veri kümesi ile bu sonuçlar FractalSpiNet %46.35, Con-FractalSpiNet %56.25 ve Att-FractalSpiNet %43.94 olarak daha az başarılı sonuçlar ile tespit edilmiştir. Diğer yapılan çalışmalar ile kıyaslandığında aksiyel verilerde omurilik MS bölütleme ile elde edilen en yüksek DSC skoru %60.4 ve %50.0 iken tümör için 76.7 ± 1.5 olarak DSC skoru tespit edilmiştir.

Tablo 6.2. FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet ile literatürde yapılmış benzer ölçekli çalışmalarının karşılaştırılması

Çalışma	Veriseti	Metot	DSC (%)
De Leener vd. (2014)	Özgün veriseti	PropSeg	90.0 (omurilik bölütleme)
De Leener vd. (2015)	Özgün veriseti	PropSeg	91.0 ± 0.02 (omurilik ve omurilik kanalının bölütlenmesi)
Prados vd. (2016)	Özgün veriseti	OPAL algoritması ve STEPS bölütleme	96.5 (Lezyonlu OKA bölütleme) 97.0 (Lezyonsuz OKA)
Gros vd. (2019)	Özgün veriseti	CNN (DeepSeg)	95.9 (omurilik bölütleme) 60.4 (MS lezyon tespiti)
Lemay vd. (2021)	Özgün veriseti	U-Net temelli kaskad mimari	76.7 ± 1.5 (Tümör + Kavite + Adem)
Zhang vd. (2021)	Özgün veriseti	U-Net	87.0 ± 18.4 (OKA bölütleme)
Zhang vd. (2022)	Özgün veriseti	Channel attentive U-Net (SeUneter)	90.67 ± 1.63 (servikal omur bölütleme)
Zhuo vd. (2022)	Özgün veriseti	MultiResUNet	50.0 (MS) 58.0 (NOSD)
Önerilen Method (Servikal Omurilik Veriseti)	"Spine generic public" veriseti	U-Net temelli soft bölütleme	96.0 ± 1 (omurilik bölütleme)
		FractalSpiNet	94.90(OKA bölütleme) 92.99(BOS bölütleme) 96.54(OKA+BOS bölütleme)
		Con-FractalSpiNet	94.99 (OKA bölütleme) 92.76(BOS bölütleme) 96.39(OKA+BOS bölütleme)
	Omurilik Aksiyel OKA/BOS	Att-FractalSpiNet	94.70 (OKA bölütleme) 92.82(BOS bölütleme) 96.25(OKA+BOS bölütleme)
		FractalSpiNet	98.88 (OKA bölütleme) 97.17 (MS'siz OKA bölütleme) 90.90 (MS lezyon tespiti)
		Con-FractalSpiNet	98.89 (OKA bölütleme) 97.25 (MS'siz OKA bölütleme) 91.48 (MS lezyon tespiti)
	Omurilik Aksiyel MS	Att-FractalSpiNet	98.41 (OKA bölütleme) 96.48 (MS'siz OKA bölütleme) 88.79 (MS lezyon tespiti)
		FractalSpiNet	96.16 (OKA bölütleme) 94.10 (MS'siz OKA bölütleme) 46.35 (MS lezyon tespiti)
		Con-FractalSpiNet	95.92 (OKA bölütleme) 93.76 (MS'siz OKA bölütleme) 56.25 (MS lezyon tespiti)
	Omurilik Sagittal MS	Att-FractalSpiNet	95.98 (OKA bölütleme) 93.83 (MS'siz OKA bölütleme) 43.94 (MS lezyon tespiti)

Omurilik aksiyel OKA/BOS verisi için toplam 1000 görüntü için %20'si test veri seti olarak ayrılmış olup 200 olarak belirlenmiştir. Omurilik aksiyel MS verisi için 1080 görüntünün %20'si test verisi olarak ayrılarak toplam 216 MR görüntüsü ve maske verisi ayrılmıştır. Üçüncü alt veri kümesi olan omurilik sagittal MS alt veri kümesinde 530 olup %20'si olan 106 adet MR görüntüsü test veri seti olarak ayrılmıştır. Tablo 6.3'te verilen zaman ölçekleri test verisetinde tüm veriler için metriklerin hesaplanması ve tahminlerin görselleştirilmesi aşamasını kapsamaktadır. Bu süreler herbir veri seti için tüm modellerin değerlendirme süreleri ölçülmüş ve herbir veri için ortalama süreleri çıkarılmıştır. Modellerin eğitimleri sonunda test verisetinin metriklerin hesaplanması ve verilerin görselleştirilmesi için geçen süre ayrı ayrı hesaplanmıştır. Toplam sürelerin test veri sayısına bölünmesi ile herbir veri için elde edilen süre de ayrı ayrı hesaplanmıştır. Tek bir aksiyel MR görüntüsü için ortalama tespit süresi tüm modeller için yaklaşık 0.2 saniye iken sagittal düzlemdeki görüntüler için bu süre 0,35 olarak tespit edilmiştir. Modeller arasında önemli bir fark olmamasına karşılık veri seti bazında farklılık verilerin boyutlarından kaynaklanmakta olduğu çıkarımı yapılabilmektedir. aksiyel görüntüler 128x128 piksel boyutunda iken, sagittal görüntüler 320x320 olduğu için piksel bazlı işlem yapan U-Net mimarilerinin sonuçlarının değerlendirme aşamasında geçen sürelerle fark olarak yansımıştır. Alınan sonuçlar test seti için hesaplanan toplam tespit süresi ve tek bir MR görüntüsü için elde edilen tespit süresi, önerilen çalışmanın gerçek zamanlı uygulamalarını gerçekleştirmeyi anlamlı kılmaktadır.

Tablo 6.3. Tüm modellerin eğitimleri sonunda herbir test seti için toplam tespit süresi ve test verisetindeki tek bir görüntü için ortalama tespit süresi

Derin Öğrenme Mimarileri	Test verisinin toplam tespit süreleri(s)			Test verisinde herbir veri için ortalama tespit süreleri(s)		
	Omurilik Aksiyel OKA/BOS	Omurilik Aksiyel MS	Omurilik Sagittal MS	Omurilik Aksiyel OKA/BOS	Omurilik Aksiyel MS	Omurilik Sagittal MS
U-Net	43.37	45.51	37.14	0.217	0.211	0.350
Att U-Net	42.14	44.82	37.31	0.211	0.208	0.352
Res U-Net	42.55	45.17	37.92	0.213	0.209	0.358
Att-Res U-Net	42.81	44.67	37.64	0.214	0.207	0.355
FractalSpiNet	42.23	44.42	37.91	0.211	0.205	0.358
Con-FractalSpiNet	41.42	44.99	37.33	0.207	0.208	0.352
Att-FractalSpiNet	43.59	44.92	37.46	0.218	0.208	0.353

7. SONUÇ

Bu tez çalışmasında omurilik bölgesinin ve omurilik MS lezyonların tespit edilmesi için derin öğrenme yöntemlerinden U-Net mimarisi tabanlı fraktal evrişim yapısına sahip yeni mimariler önerilmiştir. Deneysel çalışmalarda, önerilen FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet modellerinin diğer U-Net modellerine göre daha başarılı sonuçlar elde ettiği görülmüştür. Tüm deneysel aşamalarda modellerin ayarlamaları için aynı değerlere sahip parametreler kullanılarak tüm modellerin eğitimleri sonunda her bir test verisi için metrik değerleri hesaplanmıştır. Elde edilen tüm sonuçlar birebir aynı çalışmalar olmasa bile literatürde yapılmış benzer çalışmalar ile kıyaslanarak model ve verisetleri hakkında elde edilen bulgular ölçeğince değerlendirmeler yapılmıştır.

Omurilik, yapısal olarak belirli bir geometrik şekle sahip olmayıp, vertebral yapıya karşılık gelen kavisli bir yapıya sahiptir. Bu nedenle bölgeyi segmente etmek ve sınırlarını belirlemek oldukça zorlu bir iştir. Omurilik sınırlarının omurilik boyunca değişken bir şekle sahip olması ve omurilikte tespit edilecek lezyonların konum, boyut ve şekil açısından heterojen olması, hazırladığımız veri seti gruplarına çeşitlilik açısından olumlu etkisi olmakla birlikte bölütleme için dikkate alınması gereken önemli bir ayrıntıdır. Bu çalışmada, fraktal evrişim tabanlı hibrit U-Net mimarisi olarak önerilen FractalSpiNet, Con-FractalSpiNet, Att-FractalSpiNet modelleri ve diğer rekabetçi mimariler kullanılarak servikal omuriliğin otomatik bölütleme ve omurilik MS lezyonlarının tespiti gerçekleştirilmiştir. Önerilen FractalSpiNet ve Con-FractalSpiNet mimarileri birçok bölütleme çalışması sonunda oldukça yüksek DSC skoru elde ederek diğer modellere üstünlük sağlamıştır. Aksiyel kesitlerde MS lezyonlarının tespit edilmesi sagittal verilere göre oldukça yüksek ve başarılı örtüşme yeteneği sergilemiştir. Özetle, deneysel sonuçlar servikal omurilik ve MS lezyonlarının doğru bölütleme skorları elde etmede model yaklaşımlarımızın etkinliğini, en son yöntemleri geride bıraktığı veya çok yakın sonuçlar elde ettiği gözlemlenmektedir.

En genel anlamda, önerilen FractalSpiNet ve Con-FractalSpiNet mimarileri veriseti bazında değişkenlik göstererek temel U-Net modelinden daha yüksek performans elde etmiştir. Bu yöntemin gelecekteki yeni mimariler için geliştirilebileceği öngörülmektedir. Servikal omuriliği doğru bir şekilde bölütlenmesi ve MR görüntülerinden MS lezyonlarını tespit etme yeteneği, hasta bakımı için derin etkilere sahiptir. MS lezyonlarının erken ve kesin bir şekilde tanımlanması, zamanında müdahale

için çok önemlidir. Potansiyel olarak hastalığın ilerlemesini yavaştıp hastanın tedavi sürecini olumlu katkı sunması açısından çok önemli bir çalışmadır.

FractalSpiNet, Con-FractalSpiNet ve Att-FractalSpiNet modelleri radyologların doğruluğunu ve verimliliğini artırmasına katkı sunarak manuel bölütleme için gereken süreyi azaltabilir ve tanısal güveni artırabilmektedir. Bu daha kişiselleştirilmiş ve etkili tedavi planlarına yol açabilmekte, MS ve omurilikle ilgili diğer rahatsızlıkları olan hastaların yaşam kalitesini iyileştirebilmektedir. MR görüntülemeye gelinen noktada çekim aşamasında teknoloji açısından MS gibi lezyon bölgelerine odaklanmak henüz mümkün değildir ve genel MR verilerinde çok fazla gereksiz alan vardır. Bu nedenle, omuriliğin aksiyel düzlem MR görüntüsü, kapladığı alan açısından çok küçük bir alana karşılık gelir ve bu sınırlar içindeki MS lezyonları çok daha küçük piksel değerlerine karşılık gelmektedir. Bu kadar küçük alanları maskelemek, deneyimli uzmanlar için bile çok zordur ve hata olasılığı devam etmektedir. Bu bağlamda, omuriliğin, omurilik içindeki farklı birimlerin ve omurilik bölgesindeki MS lezyonlarının derin öğrenme mimarileriyle bölütleme, veri setinin hazırlanmasındaki zorluklar nedeniyle çok sınırlı kalmaktadır. Ayrıca, lezyon yoğunluklarının gri madde yoğunluklarına ve diğer bazı dokusal yapılara benzerliği, manuel maskeleme süreçlerinde hata olasılığını artıran diğer faktörlerdendir. Maskelemenin doğru şekilde gerçekleştirilememesi, nihayetinde eğitim başarısızlığına ve daha sonra omurilik ve MS lezyonlarının daha düşük performansla tespit edilmesine yol açması muhtemeldir.

Bu tez çalışmasında da, aksiyel ve sagittal açıdan taranan servikal omuriliğin MR kesitleri kullanılarak yeni bir veriseti oluşturulmuştur. Bu veri seti için, omurilik bölgesi ve MS lezyonları için gerçek maske verileri, iki deneyimli radyoloğun fikir birliğiyle oluşturulmuştur. Veri setindeki MR görüntüleri yalnızca omuriliğin servikal bölgesinden taranmakta ve daha ileri çalışmalar için, omuriliğin torasik ve lomber bölgelerinden görüntüler taranarak MS lezyonu, tüm omurilik boyunca segmentlere ayrılmıştır.

Çalışmaya katkı sunacak diğer çalışmalar kısaca optimisasyon algoritmaları ile birçok farklı kombinasyonda model eğitimleri yapılarak bu modellerin eğitim başarısına olan katkısı incelenebilir, model eğitimlerinde yapılan ön işlem çalışmalarında yapılacak olan değişiklik (görüntü formatı, görüntü boyutu, görüntü sayısı vb.) göstermesi ağın performansına olan etkisi, diğer karma U-Net modeller ile kıyaslanması gibi yapılacak birçok çalışma şeklinde sıralanabilmektedir. Ayrıca elde edilen başarılı sonuçlar sayesinde karar destek sistemlerin klinik ortamlarda uygulayıcılara oldukça faydalı olabileceği değerlendirilmektedir. Her ne kadar aksiyel kesitler kullanılarak MS

lezyonlarının farklı yol ve yöntemlerle tespit edilmesi için çalışılmış olsa bile açık kaynak (publicly- available) paylaşılan bir veriseti olmadığından birebir veri seti kıyaslaması yapılamamıştır. Gerçek maske (ground truth) işleminin her ne kadar iki uzman tarafından yapılmış olsa bile bu işlemin manuel olarak yapılması yapılan işlemin hataya hala açık olduğunu göstermektedir. Bununla beraber her ne kadar farklı planellerden veriler kullanılarak sistemin kararlılığı test edilmiş olsa bile farklı yoğunluklara sahip MR görüntülerinin verisetlerine dahil edilmesi verisetinin daha genelleştirerek model tahmin yeteneğini nasıl etkileyeceği diğer bir çalışma konusu olabilecek değerlidir.



KAYNAKÇA

- Abraham, N., &Khan, N. M.** (2019). *A novel focal tversky loss function with improved attention u-net for lesion segmentation*. Paper presented at the 2019 IEEE 16th international symposium on biomedical imaging (ISBI 2019).
- Alcaide-Leon, P., Pauranik, A., Alshafai, L., Rawal, S., Oh, J., Montanera, W., Leung, G., &Bharatha, A.** (2016). Comparison of sagittal FSE T2, STIR, and T1-weighted phase-sensitive inversion recovery in the detection of spinal cord lesions in MS at 3T. *American Journal of Neuroradiology*, 37(5), 970.
- Alom, M. Z., Yakopcic, C., Taha, T. M., &Asari, V. K.** (2018). *Nuclei segmentation with recurrent residual convolutional neural networks based U-Net (R2U-Net)*. Paper presented at the NAECON 2018-IEEE National Aerospace and Electronics Conference.
- Alsenan, A., Youssef, B. B., &Alhichri, H.** (2021). *A Deep Learning Model based on MobileNetV3 and UNet for Spinal Cord Gray Matter Segmentation*. Paper presented at the 2021 44th International Conference on Telecommunications and Signal Processing (TSP).
- Altman, J., &Bayer, S. A.** (2001). *Development of the human spinal cord: an interpretation based on experimental studies in animals*: Oxford University Press.
- Amukotuwa, S. A., &Cook, M. J.** (2007). Spinal disease: neoplastic, degenerative, and infective spinal cord diseases and spinal cord compression. In *Neurology and Clinical Neuroscience* (pp. 511): Mosby International.
- AskariHemmat, M., Honari, S., Rouhier, L., Perone, C. S., Cohen-Adad, J., Savaria, Y., &David, J.-P.** (2019). U-Net fixed-point quantization for medical image segmentation. In *Large-Scale Annotation of Biomedical Data and Expert Label Synthesis and Hardware Aware Learning for Medical Imaging and Computer Assisted Intervention* (pp. 115): Springer.
- Asman, A. j., Bryan, F. w., Smith, S. a., Reich, D. s., &Landman, B.** (2014). Groupwise multi-atlas segmentation of the spinal cord's internal structure. *Medical image analysis*, 18(3), 460.
- Atlan, F., Hançer, E., &Pençe, İ.** (2020). U-Net ile Çekirdek Segmentasyonunda Hiper Parametre Optimizasyonu Etkisinin Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 60.
- Awad, A., Hemmer, B., Hartung, H.-P., Kieseier, B., Bennett, J. L., &Stuve, O.** (2010). Analyses of cerebrospinal fluid in the diagnosis and monitoring of multiple sclerosis. *Journal of neuroimmunology*, 219(1-2), 1.
- Azad, R., Aghdam, E. K., Rauland, A., Jia, Y., Avval, A. H., Bozorgpour, A., Karimijafarbigloo, S., Cohen, J. P., Adeli, E., &Merhof, D.** (2024). Medical image segmentation review: The success of u-net. *IEEE Transactions on Pattern Analysis Machine Intelligence*, 1
- Bédard, S., &Cohen-Adad, J.** (2022). Automatic measure and normalization of spinal cord cross-sectional area using the pontomedullary junction. *Frontiers in Neuroimaging*, 1, 1031253.
- Bjorck, N., Gomes, C. P., Selman, B., &Weinberger, K. Q. J. A. i. n. i. p. s.** (2018). Understanding batch normalization. 31.
- Bot, J. C., Barkhof, F., à Nijeholt, G. L., Van Schaardenburg, D., Voskuyl, A. E., Ader, H. J., Pijnenburg, J. A., Polman, C. H., Uitdehaag, B. M., &Vermeulen, E. G.**

(2002). Differentiation of multiple sclerosis from other inflammatory disorders and cerebrovascular disease: value of spinal MR imaging. *Radiology*, 223(1), 46.

Bot, J. C., Barkhof, F., Polman, C., à Nijeholt, G. L., De Groot, V., Bergers, E., Ader, H., &Castelijns, J. (2004). Spinal cord abnormalities in recently diagnosed MS patients: added value of spinal MRI examination. *Neurology*, 62(2), 226.

Chen, B., Liu, Y., Zhang, Z., Lu, G., &Kong, A. W. K. (2023). Transattunet: Multi-level attention-guided u-net with transformer for medical image segmentation. *IEEE Transactions on Emerging Topics in Computational Intelligence*.

Chen, J., Lu, Y., Yu, Q., Luo, X., Adeli, E., Wang, Y., Lu, L., Yuille, A. L., &Zhou, Y. (2021). Transunet: Transformers make strong encoders for medical image segmentation. *arXiv preprint arXiv:2102.04306*.

Chen, M., Carass, A., Oh, J., Nair, G., Pham, D. L., Reich, D. S., &Prince, J. L. (2013). Automatic magnetic resonance spinal cord segmentation with topology constraints for variable fields of view. *Neuroimage*, 83, 1051.

Chen, Y., Haacke, E. M., &Bernitsas, E. (2020). Imaging of the spinal cord in multiple sclerosis: past, present, future. *Brain Sciences*, 10(11), 857.

Christogianni, A., Bibb, R., Davis, S. L., Jay, O., Barnett, M., Evangelou, N., &Filingeri, D. (2018). Temperature sensitivity in multiple sclerosis: an overview of its impact on sensory and cognitive symptoms. *Temperature*, 5(3), 208.

Ciresan, D., Giusti, A., Gambardella, L., &Schmidhuber, J. (2012). Deep neural networks segment neuronal membranes in electron microscopy images. *Advances in neural information processing systems*, 25.

Coulon, O., Hickman, S., Parker, G., Barker, G., Miller, D., &Arridge, S. (2002). Quantification of spinal cord atrophy from magnetic resonance images via a B-spline active surface model. *Magnetic Resonance in Medicine: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 47(6), 1176.

Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., &Ronneberger, O. (2016). *3D U-Net: learning dense volumetric segmentation from sparse annotation*. Paper presented at the Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II 19.

De Leener, B., Cohen-Adad, J., &Kadoury, S. (2015). Automatic segmentation of the spinal cord and spinal canal coupled with vertebral labeling. *IEEE transactions on medical imaging*, 34(8), 1705.

De Leener, B., Kadoury, S., &Cohen-Adad, J. (2014). Robust, accurate and fast automatic segmentation of the spinal cord. *Neuroimage*, 98, 528.

De Leener, B., Taso, M., Cohen-Adad, J., &Callot, V. (2016). Segmentation of the human spinal cord. *Magnetic Resonance Materials in Physics, Biology Medicine*, 29(2), 125.

Dilokthornsakul, P., Valuck, R. J., Nair, K. V., Corboy, J. R., Allen, R. R., &Campbell, J. D. (2016). Multiple sclerosis prevalence in the United States commercially insured population. *Neurology*, 86(11), 1014.

Duman, F. (2009). Sağlıklı bireylerde MRG ile servikal spinal kord ve aynı seviyedeki kanalis vertebralis alanlarının karşılaştırmalı incelenmesi.

- El Mendili, M. M., Chen, R., Tired, B., Péligrini-Issac, M., Cohen-Adad, J., Lehericy, S., Pradat, P. F., & Benali, H.** (2015). Validation of a semiautomated spinal cord segmentation method. *Journal of Magnetic Resonance Imaging*, 41(2), 454.
- Fan, T., Wang, G., Li, Y., & Wang, H.** (2020). Ma-net: A multi-scale attention network for liver and tumor segmentation. *IEEE Access*, 8, 179656.
- Fei, N., Li, G., Wang, X., Li, J., Hu, X., & Hu, Y. J. D.** (2023). Deep Learning-Based Auto-Segmentation of Spinal Cord Internal Structure of Diffusion Tensor Imaging in Cervical Spondylotic Myelopathy. *13*(5), 817.
- Feurer, M., & Hutter, F.** (2019). Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 3.
- Filippi, M., Horsfield, M., Morrissey, S., MacManus, D., Rudge, P., McDonald, W., & Miller, D.** (1994). Quantitative brain MRI lesion load predicts the course of clinically isolated syndromes suggestive of multiple sclerosis. *Neurology*, 44(4), 635.
- Filippi, M., Preziosa, P., Banwell, B. L., Barkhof, F., Ciccarelli, O., De Stefano, N., Geurts, J. J., Paul, F., Reich, D. S., & Toosy, A. T. J. B.** (2019). Assessment of lesions on magnetic resonance imaging in multiple sclerosis: practical guidelines. *142*(7), 1858.
- Fonov, V. S., Le Troter, A., Taso, M., De Leener, B., Lévêque, G., Benhamou, M., Sdika, M., Benali, H., Pradat, P.-F., & Collins, D. L.** (2014). Framework for integrated MRI average of the spinal cord white and gray matter: the MNI-Poly-AMU template. *Neuroimage*, 102, 817.
- Galler, S., Stellmann, J.-P., Young, K., Kutzner, D., Heesen, C., Fiehler, J., & Siemonsen, S.** (2016). Improved lesion detection by using axial T2-weighted MRI with full spinal cord coverage in multiple sclerosis. *American Journal of Neuroradiology*, 37(5), 963.
- Garg, S., & Bhagyashree, S.** (2021). Spinal cord MRI segmentation techniques and algorithms: A survey. *SN Computer Science*, 2(3), 229.
- Goodfellow, I.** (2016). Deep learning. In: MIT press.
- Granieri, E.** (2000). Exogenous factors in the aetiology of multiple sclerosis. *Journal of neurovirology*, 6, S141.
- Grigoriadis, N., & Van Pesch, V.** (2015). A basic overview of multiple sclerosis immunopathology. *European journal of neurology*, 22, 3.
- Gros, C., De Leener, B., Badji, A., Maranzano, J., Eden, D., Dupont, S. M., Talbott, J., Zhuoquiong, R., Liu, Y., & Granberg, T.** (2019). Automatic segmentation of the spinal cord and intramedullary multiple sclerosis lesions with convolutional neural networks. *Neuroimage*, 184, 901.
- Gros, C., De Leener, B., Dupont, S. M., Martin, A. R., Fehlings, M. G., Bakshi, R., Tummala, S., Auclair, V., McLaren, D. G., & Callot, V.** (2018). Automatic spinal cord localization, robust to MRI contrasts using global curve optimization. *Medical image analysis*, 44, 215.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., & Cai, J.** (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354.
- Guo, C., Szemenyei, M., Yi, Y., Wang, W., Chen, B., & Fan, C.** (2021). *Sa-unet: Spatial attention u-net for retinal vessel segmentation*. Paper presented at the 2020 25th international conference on pattern recognition (ICPR).

- Gülcü, A., & Kuş, Z.** (2019). A survey of hyper-parameter optimization methods in convolutional neural networks. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 7(2), 503.
- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). *Deep residual learning for image recognition*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Herholz, K., Salmon, E., Perani, D., Baron, J.-C., Holthoff, V., Frölich, L., Schönknecht, P., Ito, K., Mielke, R., & Kalbe, E.** (2002). Discrimination between Alzheimer dementia and controls by automated analysis of multicenter FDG PET. *Neuroimage*, 17(1), 302.
- Hille, G., Steffen, J., Dünnwald, M., Becker, M., Saalfeld, S., & Tönnies, K.** (2020). Spinal metastases segmentation in MR imaging using deep convolutional neural networks. *arXiv preprint arXiv:2005.05834*.
- Hinton, G.** (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.
- Horsfield, M. A., Sala, S., Neema, M., Absinta, M., Bakshi, A., Sormani, M. P., Rocca, M. A., Bakshi, R., & Filippi, M.** (2010). Rapid semi-automatic segmentation of the spinal cord from magnetic resonance images: application in multiple sclerosis. *Neuroimage*, 50(2), 446.
- Horváth, A., Tsagkas, C., Andermatt, S., Pezold, S., Parmar, K., & Cattin, P.** (2019). *Spinal cord gray matter-white matter segmentation on magnetic resonance AMIRA images with MD-GRU*. Paper presented at the Computational Methods and Clinical Applications for Spine Imaging: 5th International Workshop and Challenge, CSI 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 16, 2018, Revised Selected Papers 5.
- Ioffe, S.** (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv preprint arXiv:1502.03167*.
- Jois, S. S., Sridhar, H., & Kumar, J. H.** (2018). *A fully automated spinal cord segmentation*. Paper presented at the 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP).
- Karkucak, A., & Köksal, V.** (2021). İntramedüller Spinal Kord Tümörleri ve Cerrahi Tedavinin Yönetimi. *Türk Nöroşirürji Dergisi*, 31(1), 147.
- Kawahara, J., McIntosh, C., Tam, R., & Hamarneh, G.** (2013). *Globally optimal spinal cord segmentation using a minimal path in high dimensions*. Paper presented at the 2013 IEEE 10th International Symposium on Biomedical Imaging.
- Kearney, H., Miller, D. H., & Ciccarelli, O. J. N. R. N.** (2015). Spinal cord MRI in multiple sclerosis—diagnostic, prognostic and clinical value. *11*(6), 327.
- Kim, H. J., Paul, F., Lana-Peixoto, M. A., Tenenbaum, S., Asgari, N., Palace, J., Klawiter, E. C., Sato, D. K., de Seze, J., & Wuerfel, J.** (2015). MRI characteristics of neuromyelitis optica spectrum disorder: an international update. *Neurology*, 84(11), 1165.
- Klug, J., Leclerc, G., Dirren, E., Preti, M. G., Van De Ville, D., & Carrera, E.** (2021). *Bayesian skip net: building on prior information for the prediction and segmentation of stroke lesions*. Paper presented at the Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, Held in Conjunction with MICCAI 2020, Lima, Peru, October 4, 2020, Revised Selected Papers, Part I 6.

- Koh, J., Kim, T., Chaudhary, V., &Dhillon, G.** (2010). *Automatic segmentation of the spinal cord and the dural sac in lumbar MR images using gradient vector flow field*. Paper presented at the 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology.
- Koh, J., Scott, P. D., Chaudhary, V., &Dhillon, G.** (2011). *An automatic segmentation method of the spinal canal from clinical MR images based on an attention model and an active contour model*. Paper presented at the 2011 IEEE International Symposium on Biomedical Imaging: From Nano to Macro.
- Kohl, S., Romera-Paredes, B., Meyer, C., De Fauw, J., Ledsam, J. R., Maier-Hein, K., Eslami, S., Jimenez Rezende, D., &Ronneberger, O.** (2018). A probabilistic u-net for segmentation of ambiguous images. *Advances in neural information processing systems*, 31.
- Krizhevsky, A., Sutskever, I., &Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Kusrini, K., Suputa, S., Setyanto, A., Agastya, I. M. A., Priantoro, H., Chandramouli, K., &Izquierdo, E.** (2020). Data augmentation for automated pest classification in Mango farms. *Computers Electronics in Agriculture*, 179, 105842.
- Lachinov, D., Vasiliev, E., &Turlapov, V.** (2018). *Glioma segmentation with cascaded UNet*. Paper presented at the International MICCAI Brainlesion Workshop.
- Larsson, G., Maire, M., &Shakhnarovich, G.** (2016). Fractalnet: Ultra-deep neural networks without residuals. *arXiv preprint arXiv:1605.07648*.
- Law, M. W., Garvin, G. J., Tummala, S., Tay, K., Leung, A. E., &Li, S.** (2013). *Gradient competition anisotropy for centerline extraction and segmentation of spinal cords*. Paper presented at the Information Processing in Medical Imaging: 23rd International Conference, IPMI 2013, Asilomar, CA, USA, June 28–July 3, 2013. Proceedings 23.
- LeCun, Y., Bengio, Y., &Hinton, G.** (2015). Deep learning. *nature*, 521(7553), 436.
- Lemay, A., Gros, C., Zhuo, Z., Zhang, J., Duan, Y., Cohen-Adad, J., &Liu, Y.** (2021). Automatic multiclass intramedullary spinal cord tumor segmentation on MRI with deep learning. *NeuroImage: Clinical*, 31, 102766.
- Losseff, N., Webb, S., O'riordan, J., Page, R., Wang, L., Barker, G., Tofts, P. S., McDonald, W. I., Miller, D. H., &Thompson, A. J.** (1996). Spinal cord atrophy and disability in multiple sclerosis: a new reproducible and sensitive MRI method with potential to monitor disease progression. *Brain Sciences*, 119(3), 701.
- Lu, X., Clements-Croome, D., &Viljanen, M.** (2012). Fractal geometry and architecture design: case study review. *Chaotic Modeling Simulation*, 2, 311.
- McCoy, D., Dupont, S., Gros, C., Cohen-Adad, J., Huie, R., Ferguson, A., Duong-Fernandez, X., Thomas, L., Singh, V., &Narvid, J.** (2019). Convolutional neural network–based automated segmentation of the spinal cord and contusion injury: Deep learning biomarker correlates of motor impairment in acute spinal cord injury. *American Journal of Neuroradiology*, 40(4), 737.
- McDonald, W. I., Compston, A., Edan, G., Goodkin, D., Hartung, H. P., Lublin, F. D., McFarland, H. F., Paty, D. W., Polman, C. H., &Reingold, S. C.** (2001). Recommended diagnostic criteria for multiple sclerosis: guidelines from the International

Panel on the diagnosis of multiple sclerosis. *Annals of Neurology: Official Journal of the American Neurological Association the Child Neurology Society*, 50(1), 121.

Mendili, M.-M. E., Chen, R., Tiret, B., Villard, N., Trunet, S., Pélégriani-Issac, M., Lehericy, S., Pradat, P.-F., & Benali, H. (2015). Fast and Accurate Semi-Automated Segmentation Method of Spinal Cord MR Images at 3T Applied to the Construction of a Cervical Spinal Cord Template. *PLOS ONE*, 10(3), 1.

Merali, Z., Wang, J. Z., Badhiwala, J. H., Witiw, C. D., Wilson, J. R., & Fehlings, M. G. (2021). A deep learning model for detection of cervical spinal cord compression in MRI scans. *Scientific reports*, 11(1), 10473.

Miller, D., Barkhof, F., Montalban, X., Thompson, A., & Filippi, M. (2005). Clinically isolated syndromes suggestive of multiple sclerosis, part I: natural history, pathogenesis, diagnosis, and prognosis. *The Lancet Neurology*, 4(5), 281.

Milletari, F., Navab, N., & Ahmadi, S.-A. (2016). *V-net: Fully convolutional neural networks for volumetric medical image segmentation*. Paper presented at the 2016 fourth international conference on 3D vision (3DV).

Mirafzal, S., Goujon, A., Deschamps, R., Zuber, K., Sadik, J., Gout, O., Lecler, A., & Savatovsky, J. (2020). 3D PSIR MRI at 3 Tesla improves detection of spinal cord lesions in multiple sclerosis. *Journal of Neurology*, 267, 406.

Mirza, M. (2002). The etiology and the epidemiology of multiple sclerosis. *Erciyes tıp dergisi= Erciyes Medical Journal*, 24(1), 40.

Moccia, M., Ruggieri, S., Ianniello, A., Toosy, A., Pozzilli, C., & Ciccarelli, O. J. T. a. i. n. d. (2019). Advances in spinal cord imaging in multiple sclerosis. 12, 1756286419840593.

Mortazavi, D., Kouzani, A. Z., & Soltanian-Zadeh, H. (2012). Segmentation of multiple sclerosis lesions in MR images: a review. *Neuroradiology*, 54, 299.

Nair, V., & Hinton, G. E. (2010). *Rectified linear units improve restricted boltzmann machines*. Paper presented at the Proceedings of the 27th international conference on machine learning (ICML-10).

Nouri, A., Tetreault, L., Singh, A., Karadimas, S. K., & Fehlings, M. G. (2015). Degenerative cervical myelopathy: epidemiology, genetics, and pathogenesis. *Spine*, 40(12), E675.

Oktay, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., & Kainz, B. (2018). Attention u-net: Learning where to look for the pancreas. *arXiv preprint arXiv:1804.03999v3*.

Olsson, T., Barcellos, L. F., & Alfredsson, L. (2017). Interactions between genetic, lifestyle and environmental risk factors for multiple sclerosis. *Nature Reviews Neurology*, 13(1), 25.

Öztürk, M., & Tek, Ş. (2019). MULTİPL SKLEROZ (MS) HASTALARININ YAŞAM KALİTESİNİN YORDANMASINDA SOSYODEMOGRAFİK DEĞİŞKENLERİN VE ALGILANAN SOSYAL DESTEĞİN ETKİSİ. (14), 10.

Öztürk, S., Aytaç, G., Kızılay, F., & Sindel, M. (2017). Multipl Skleroz. *Akdeniz Tıp Dergisi*, 3(3), 137.

Patek, M., & Stewart, M. (2023). Spinal cord injury. *Anaesthesia Intensive Care Medicine*, 24(7), 406.

Pattanayak, S. (2023). *Pro deep learning with tensorflow 2.0: A mathematical approach to advanced artificial intelligence in python*: Springer.

Paugam, F., Lefeuvre, J., Perone, C. S., Gros, C., Reich, D. S., Sati, P., & Cohen-Adad, J. (2019). Open-source pipeline for multi-class segmentation of the spinal cord with deep learning. *Magnetic resonance imaging*, 64, 21.

Perone, C. S., Calabrese, E., & Cohen-Adad, J. (2018). Spinal cord gray matter segmentation using deep dilated convolutions. *Sci Rep*, 8(1), 1.

Pezold, S., Fundana, K., Amann, M., Andelova, M., Pfister, A., Sprenger, T., & Cattin, P. C. (2015). Automatic segmentation of the spinal cord using continuous max flow with cross-sectional similarity prior and tubularity features. In *Recent Advances in Computational Methods and Clinical Applications for Spine Imaging* (pp. 107): Springer.

Polattimur, R., & Dandil, E. (2023). Automatic Segmentation of Spinal Cord Gray Matter from MR Images using a U-Net Architecture. In *Explainable Artificial Intelligence for Biomedical Applications* (pp. 245): River Publishers.

Polattimur, R., Dandil, E., Yıldırım, M. S., Şenol, A. U., Tezel, Z. E., Selvi, A. O., & Kabay, S. C. (2023). *Fully automated axial plane segmentation of cervical spinal cord using U-Net in MR scans*. Paper presented at the 2023 7th International Symposium on Innovative Approaches in Smart Technologies (ISAS).

Polattimur, R., Dandil, E., Yildirim, M. S., Uluçay, S., & Şenol, U. (2024). FractalSpiNet: Fractal-Based U-Net for Automatic Segmentation of Cervical Spinal Cord and MS Lesions in MRI. *IEEE Access*.

Prados, F., Ashburner, J., Blaiotta, C., Brosch, T., Carballido-Gamio, J., Cardoso, M. J., Conrad, B. N., Datta, E., Dávid, G., & De Leener, B. (2017). Spinal cord grey matter segmentation challenge. *Neuroimage*, 152, 312.

Prados, F., Cardoso, M. J., Yiannakas, M. C., Hoy, L. R., Tebaldi, E., Kearney, H., Liechti, M. D., Miller, D. H., Ciccarelli, O., Wheeler-Kingshott, C. A., & Ourselin, S. (2016). Fully automated grey and white matter spinal cord segmentation. *Sci Rep*, 6, 36151. doi:10.1038/srep36151

Pugliatti, M., Sotgiu, S., & Rosati, G. (2002). The worldwide prevalence of multiple sclerosis. *Clinical neurology neurosurgery*, 104(3), 182.

Reza, S. M., Roy, S., Park, D. M., Pham, D. L., & Butman, J. A. (2019). *Cascaded convolutional neural networks for spine chordoma tumor segmentation from MRI*. Paper presented at the Medical Imaging 2019: Biomedical Applications in Molecular, Structural, and Functional Imaging.

Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-net: Convolutional networks for biomedical image segmentation*. Paper presented at the International Conference on Medical image computing and computer-assisted intervention.

Sabaghian, S., Dehghani, H., Batouli, S. A. H., Khatibi, A., & Oghabian, M. A. (2020). Fully automatic 3D segmentation of the thoracolumbar spinal cord and the vertebral canal from T2-weighted MRI using K-means clustering algorithm. *Spinal Cord*, 58(7), 811.

Sadovnick, A. D., & Ebers, G. (1993). Epidemiology of multiple sclerosis: a critical overview. *Canadian Journal of Neurological Sciences*, 20(1), 17.

Sakib, S., Ahmed, N., Kabir, A. J., & Ahmed, H. (2019). An overview of convolutional neural network: Its architecture and applications. *Preprints 2018*, 2018110546.

- Sawcer, S., Jones, H. B., Feakes, R., Gray, J., Smaldon, N., Chataway, J., Robertson, N., Clayton, D., Goodfellow, P. N., & Compston, A. (1996). A genome screen in multiple sclerosis reveals susceptibility loci on chromosome 6p21 and 17q22. *Nature genetics*, 13(4), 464.
- Siddique, N., Sidike, P., Elkin, C., & Devabhaktuni, V. (2020). U-Net and its variants for medical image segmentation: theory and applications. *arXiv preprint arXiv:01118*, 1118.
- Stroman, P. W., Wheeler-Kingshott, C., Bacon, M., Schwab, J., Bosma, R., Brooks, J., Cadotte, D., Carlstedt, T., Ciccarelli, O., & Cohen-Adad, J. (2014). The current state-of-the-art of spinal cord imaging: methods. *Neuroimage*, 84, 1070.
- Taso, M., Le Troter, A., Sdika, M., Cohen-Adad, J., Arnoux, P.-J., Guye, M., Ranjeva, J.-P., & Callot, V. (2015). A reliable spatially normalized template of the human spinal cord—Applications to automated white matter/gray matter segmentation and tensor-based morphometry (TBM) mapping of gray matter alterations occurring with age. *Neuroimage*, 117, 20.
- Tench, C. R., Morgan, P. S., & Constantinescu, C. S. (2005). Measurement of cervical spinal cord cross-sectional area by MRI using edge detection and partial volume correction. *Journal of Magnetic Resonance Imaging: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 21(3), 197.
- Thompson, A. J., Banwell, B. L., Barkhof, F., Carroll, W. M., Coetzee, T., Comi, G., Correale, J., Fazekas, F., Filippi, M., & Freedman, M. S. (2018). Diagnosis of multiple sclerosis: 2017 revisions of the McDonald criteria. *The Lancet Neurology*, 17(2), 162.
- Toğrol, E., & Demir, S. (2013). MULTİPL SKLEROZ VE İLİŞKİLİ HASTALIKLARIN TANI VE İZLEMİNDE MANYETİK REZONANS İNCELEME İLKELERİ. *Yayınevi/Publishing House*, 15.
- Ünal, A., Mavioğlu, H., Altunrende, B., İçen, N., & Ergün, U. (2018). Multipl sklerozda tanı ve ayırıcı tanı. *Multipl Skleroz Tanı ve Tedavi Kılavuzu. Efendi, H. Kuşçu, DY*, 9.
- Van Uitert, R., Bitter, I., & Butman, J. A. (2005). *Semi-automatic spinal cord segmentation and quantification*. Paper presented at the International Congress Series.
- Wattjes, M., Steenwijk, M., & Stangel, M. J. C. n. (2015). MRI in the diagnosis and monitoring of multiple sclerosis: an update. 25, 157.
- Weier, K., Mazraeh, J., Naegelin, Y., Thoeni, A., Hirsch, J. G., Fabbro, T., Bruni, N., Duyar, H., Bendfeldt, K., & Radue, E.-W. (2012). Biplanar MRI for the assessment of the spinal cord in multiple sclerosis. *Multiple Sclerosis Journal*, 18(11), 1560.
- Weinshenker, B. G. (1996). Epidemiology of multiple sclerosis. *Neurologic clinics*, 14(2), 291.
- Wenxuan, W., Chen, C., Meng, D., Hong, Y., Sen, Z., & Jiangyun, L. (2021). *Transbts: Multimodal brain tumor segmentation using transformer*. Paper presented at the International Conference on Medical Image Computing and Computer-Assisted Intervention, Springer.
- Wheeler-Kingshott, C., Stroman, P. W., Schwab, J., Bacon, M., Bosma, R., Brooks, J., Cadotte, D., Carlstedt, T., Ciccarelli, O., & Cohen-Adad, J. (2014). The current state-of-the-art of spinal cord imaging: applications. *Neuroimage*, 84, 1082.
- Wu, J. (2017). Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23), 495.

- Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K.** (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9, 611.
- Yiannakas, M. C., Mustafa, A. M., De Leener, B., Kearney, H., Tur, C., Altmann, D. R., De Angelis, F., Plantone, D., Ciccarelli, O., & Miller, D. H.** (2016). Fully automated segmentation of the cervical cord from T1-weighted MRI using PropSeg: application to multiple sclerosis. *NeuroImage: Clinical*, 10, 71.
- Yıldırım, Y., & Fadiloğlu, Ç.** (2014). MULTİPLE SKLEROZ VE EVDE BAKIM. *Ege Üniversitesi Hemşirelik Fakültesi Dergisi*, 30(2), 100.
- Yu, T., & Zhu, H.** (2020). Hyper-parameter optimization: A review of algorithms and applications. *arXiv preprint arXiv:2003.05689*.
- Yushkevich, P. A., Piven, J., Hazlett, H. C., Smith, R. G., Ho, S., Gee, J. C., & Gerig, G.** (2006). User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability. *Neuroimage*, 31(3), 1116.
- Zalc, B.** (2018). One hundred and fifty years ago Charcot reported multiple sclerosis as a new neurological disease. *Brain Sciences*, 141(12), 3482.
- Zeng, C., Gu, L., Liu, Z., & Zhao, S.** (2020). Review of deep learning approaches for the segmentation of multiple sclerosis lesions on brain MRI. *Frontiers in Neuroinformatics*, 14, 610967.
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. J. C. o. t. A.** (2021). Understanding deep learning (still) requires rethinking generalization. 64(3), 107.
- Zhang, J., Li, C., Kosov, S., Grzegorzek, M., Shirahama, K., Jiang, T., Sun, C., Li, Z., & Li, H.** (2021). LCU-Net: A novel low-cost U-Net for environmental microorganism image segmentation. *Pattern Recognition*, 115, 107885.
- Zhang, X., Li, Y., Liu, Y., Tang, S.-X., Liu, X., Punithakumar, K., & Shi, D.** (2021). Automatic spinal cord segmentation from axial-view MRI slices using CNN with grayscale regularized active contour propagation. *Computers in Biology Medicine*, 132, 104345.
- Zhang, X., Yang, Y., Shen, Y.-W., Li, P., Zhong, Y., Zhou, J., Zhang, K.-R., Shen, C.-Y., Li, Y., & Zhang, M.-F. J. F. i. P.** (2022). SeUneter: Channel attentive U-Net for instance segmentation of the cervical spine MRI medical image. 13, 1081441.
- Zhang, X., Zou, J., He, K., & Sun, J.** (2015). Accelerating very deep convolutional networks for classification and detection. *IEEE transactions on pattern analysis and machine intelligence*, 38(10), 1943.
- Zhang, Y., Chen, W., Chen, Y., & Tang, X.** (2018). *A post-processing method to improve the white matter hyperintensity segmentation accuracy for randomly-initialized U-net*. Paper presented at the 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP).
- Zhang, Y., Wu, J., Chen, W., Liu, Y., Lyu, J., Shi, H., Chen, Y., Wu, E. X., & Tang, X.** (2019). *Fully automatic white matter hyperintensity segmentation using U-Net and skip connection*. Paper presented at the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J.** (2018). *Unet++: A nested u-net architecture for medical image segmentation*. Paper presented at the Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop,

ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4.

Zhuo, Z., Zhang, J., Duan, Y., Qu, L., Feng, C., Huang, X., Cheng, D., Xu, X., Sun, T., & Li, Z. (2022). Automated classification of intramedullary spinal cord tumors and inflammatory demyelinating lesions using deep learning. *Radiology: Artificial Intelligence*, 4(6), e210292.

