

T.C.  
BİLECİK ŐEYH EDEBALI ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ELEKTRONİK VE BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI

**MR TARAMALARI ÜZERİNDE DERİN ÖĐRENME MODELLERİ  
KULLANILARAK MULTİPL SKLEROZ LEZYONLARININ OTOMATİK TESPİTİ  
VE DEĐİŐİMİNİN TAKİBİ**

DOKTORA TEZİ

MEHMET SÜLEYMAN YILDIRIM

TEZ DANIŐMANI  
DOĐ. DR. EMRE DANDIL

BİLECİK, 2022

10447717

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

**MR TARAMALARI ÜZERİNDE DERİN ÖĞRENME MODELLERİ  
KULLANILARAK MULTİPL SKLEROZ LEZYONLARININ OTOMATİK TESPİTİ  
VE DEĞİŞİMİNİN TAKİBİ**

DOKTORA TEZİ

MEHMET SÜLEYMAN YILDIRIM

TEZ DANIŞMANI  
DOÇ. DR. EMRE DANDIL

BİLECİK, 2022

10447717

BILECIK SEYH EDEBALI UNIVERSITY  
INSTITUTE OF SCIENCES  
DEPARTMENT OF ELECTRONIC AND COMPUTER ENGINEERING

**FOLLOW-UP AND AUTOMATIC DETECTION OF MULTIPLE SCLEROSIS  
LESIONS USING DEEP LEARNING MODELS ON MR SCANS**

DOCTORAL THESIS

MEHMET SÜLEYMAN YILDIRIM

THESIS ADVISOR  
ASSOC. PROF. DR. EMRE DANDIL

BILECIK, 2022

10447717

## BEYAN

“MR Taramaları Üzerinde Derin Öğrenme Modelleri Kullanılarak Multipl Skleroz Lezyonlarının Otomatik Tespiti ve Değişiminin Takibi” 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.			
<b>DESTEK ALINMIŞTIR</b>		<input type="checkbox"/>	<b>DESTEK ALINMAMIŞTIR</b>
<b>Destek alındı ise;</b>			
<b>Destekleyen kurum;</b>			
<b>Desteğin Türü</b>		<b>Proje Numarası</b>	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;..... .....			
<b>ETİK KURUL onayı var ise;</b>			
<b>ETİK KURUL karar tarih/sayı:</b>		T.C. Akdeniz Üniversitesi, Tıp Fakültesi, Klinik Araştırmalar Etik Kurulu Karar Tarihi: 23.06.2021 Karar Sayısı: KAEK - 461	

Mehmet Süleyman YILDIRIM

18/04/2022

## ÖNSÖZ

Multipl Skleroz (MS) hastalığı beyin ve omuriliği etkileyen yaygın bir merkezi sinir sistemi rahatsızlığıdır. Hastalığın teşhis ve tedavisinde MR görüntüleme teknolojisi önemli bir araç olarak kullanılmaktadır. Hekimler MR görüntüleri üzerinde hastalığın teşhisinde çeşitli zorluklar yaşamaktadır. Bu Doktora Tezi kapsamında, MR görüntüleri üzerinden derin öğrenme yöntemleri kullanılarak MS lezyonlarının otomatik tespiti için çalışmalar yapılmıştır. Tezde ayrıca, MS lezyonlarının tespiti için iyileştirilmiş bir derin öğrenme modeli de önerilmiştir. Bunun yanında, önerilen iyileştirilmiş bir derin öğrenme modeli aracılığıyla hekimlerin kullanabilecekleri web tabanlı bir karar destek sistemi platformu da geliştirilmiştir. Dahası, tez kapsamında Akdeniz Üniversitesi Tıp Fakültesi ile iş birliği yapılarak, akademik çalışmalara imkân sağlayacak bir MS veriseti hazırlanmıştır. Sonuç olarak, bu Doktora Tezi kapsamında önerilen / geliştirilen yöntem, araç ve modellerin MS hastalığının teşhis, tedavi ve karar verme süreçlerinde hekimlere yardımcı olabilecek zeki bir karar destek sistemi ortaya konulmuştur.

Bu tez çalışması sürecinde ve devam eden tüm akademik çalışmalarında devamlı desteği ile yanımda duran, çalışmalarımı sahiplenerek takip eden değerli danışmanım Sayın Doç. Dr. Emre DANDIL'a kıymetli katkı, emekleri için teşekkürlerimi ve saygılarımı sunarım. MS hastalığının incelenmesi konusunda engin bilgi birikimi, fikirleri ile çalışmamıza ve tez kapsamında özgün bir MS veriseti hazırlanmasına destek veren Akdeniz Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim Üyesi kıymetli Prof. Dr. Abdullah Utku ŞENOL'a teşekkür ve saygılarımı sunarım. Veri toplama ve uzman görüşlerinin hazırlanmasında yardım desteklerini esirgemeyen Akdeniz Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı Öğretim Elemanı Sayın Arş. Gör. Dr. Zülbiye Eda TEZEL'e ve tüm Akdeniz Üniversitesi Tıp Fakültesi Radyoloji Anabilim Dalı çalışanlarına teşekkürlerimi sunarım. Tez kapsamında kullanılan açık verisetlerini sunan Kıbrıs Üniversitesinin eHealth Laboratuvarına, Ljubljana Üniversitesi Tıp Merkezine, ISBI2015 ve MICCAI2008 organizasyonlarına da teşekkür ederim. Çalışma ve tüm doktora eğitimi sürecinde motivasyon, mekân ve imkân desteği sunan kıymetli dostlarım Dr. Öğr. Üyesi Mustafa ZEYTİN'e, Dr. Öğr. Üyesi M. Fatih GÖZÜKIZIL'a, Öğr. Gör. Dr. Ali Osman SELVİ'ye, Dr. Osman AKARSU'ya ve Hüseyin ÖZMEN'e teşekkürlerimi sunarım.

Uzun çalışma saatlerine rağmen desteğini hep hissettiren kızım Ecrin Zehra YILDIRIM'a, tez çalışmalarının başladığı günlerde ailemize katılan ve tez ile beraber büyüyen küçük evlatlarım; oğlum Yusuf Mirza YILDIRIM'a ve kızım İpek Feyza YILDIRIM'a,

hayatımın her anında olduđu gibi doktora eğitimimin başından beri desteđini hissettiren ve sabrını hiç esirgemeyen çok kıymetli eşim Özlem YILDIRIM'a en içten teşekkürlerimi sunarım.

**Mehmet Süleyman YILDIRIM**

**18.04.2022**



## ÖZET

### MR TARAMALARI ÜZERİNDE DERİN ÖĞRENME MODELLERİ KULLANILARAK MULTİPL SKLEROZ LEZYONLARININ OTOMATİK TESPİTİ VE DEĞİŞİMİNİN TAKİBİ

Multipl Skleroz (MS) hastalığı genç ve orta yaşlı insanlarda sıkça görülen beyin ve omuriliği etkileyen, yaygın bir merkezi sinir sistemi (MSS) rahatsızlığıdır. MSS içinde bulunan sinir ağları üzerindeki kılıf yapısında oluşan iltihap sonucunda meydana gelen hastalık kişide önemli bilişsel kayıplara neden olur. MS hastalarında fonksiyonel yeti kayıpları ve ileri safhalarda geri dönülemez beyin hasarları da görülebilir. Bu nedenlerden dolayı MS hastalığının erken aşamada tespiti ve takibi oldukça önemlidir. MS'in teşhisinde ve takibinde manyetik rezonans (MR) görüntüleme yaygın olarak olup teşhis için genellikle en az iki farklı periyottaki taramalarda MS lezyonlarının görülmesi beklenmektedir. Hastalığın takibi MR kesitlerindeki lezyonların değişimlerinin izlenmesi ile yapılmaktadır. MS lezyonlarının boyutlarının küçük olması ve beyindeki başka nörolojik rahatsızlıklara benzemesi, MS lezyonlarının tespitini zorlaştırmaktadır. Bu tez çalışmasında, MR görüntüleri üzerinde MS lezyonlarının otomatik tespiti için iyileştirilmiş bir derin öğrenme modeli (iMask R-CNN) önerilmiştir. Bu modelde Maske-Tabanlı Bölgesel Evrişimsel Sinir Ağı (Mask R-CNN) mimarisinin tahmini önemli bölge hizalama (RoIAlign) işleminde iyileştirme yapılmıştır. Ayrıca, MS lezyonlarının tespiti için 52 hastadan periyodik olarak alınan FLAIR MR kesitlerini içeren MSAkdeniz isimli bir MR veriseti hazırlanmıştır. Tez kapsamında, ek olarak, MS lezyonlarının otomatik tespiti ve değişiminin takibi için, hekimlere yardımcı olabilecek, iMask R-CNN modelini kullanan DeepMSWeb isimli web tabanlı bir karar destek sistemi (KDS) uygulaması geliştirilmiştir. Bunun yanında, MS lezyonlarının otomatik tespiti için, önerilen iMask R-CNN modeli başta olmak üzere, MSAkdeniz veriseti ve eHealth, UMCL, ISBI2015 ve MICCAI2008 verisetleri üzerinde, iki farklı platformda beş farklı derin öğrenme modeli kullanılarak deneysel çalışmalar yürütülmüştür ve sonuçlar karşılaştırılmıştır. Önerilen iMask R-CNN kullanılarak, lezyon tespitinde, verisetlerinde Dice benzerlik katsayısı (DSC) için  $88.32 \pm 4.44$  skorları, lezyon doğru pozitif oranı (LTPR) için  $89.80 \pm 3.54$  skorları elde edilmiştir. Önerilen iMask R-CNN ve DeepMSWeb yapıları ile MS lezyonlarının tespiti ve değişiminin takibinde kullanılacak yardımcı araçlar geliştirilmiştir.

**Anahtar Kelimeler:** Multipl Skleroz, Lezyon Tespiti, Değişim Takibi, Derin Öğrenme, Mask R-CNN, Karar Destek Sistemi

## ABSTRACT

### FOLLOW-UP AND AUTOMATIC DETECTION OF MULTIPLE SCLEROSIS LESIONS USING DEEP LEARNING MODELS ON MR SCANS

Multiple Sclerosis (MS) is a common central nervous system (CNS) disorder that affects the brain and spinal cord, which is common in young and middle-aged people. The disease that occurs as a result of inflammation in the sheath structure on the neural networks in the CNS causes significant cognitive losses in the person. Loss of functional ability and irreversible brain damage can be seen in advanced stages in MS patients. For these reasons, early detection and follow-up of MS disease is very important. Magnetic resonance (MR) imaging is common in the diagnosis and follow-up of MS, and MS lesions are generally expected to be seen on scans of at least two different periods. The follow-up of the disease is determined by following the changes of the lesions in the MR sections. MS lesions are small in size and resemble other neurological disorders in the brain, making it difficult to detect MS lesions. In this thesis, an improved deep learning model (iMask R-CNN) is proposed for automatic detection of MS lesions on MR images. In this model, the prediction important region alignment (RoIAlign) process of Mask-Based Regional Convolutional Neural Network (Mask R-CNN) architecture is improved. In addition, an MR dataset named MSAkdeniz has been prepared, which includes FLAIR MR sections periodically obtained from 52 patients for the detection of MS lesions. Moreover, a web-based decision support system (DSS) application named DeepMSWeb, which uses the iMask R-CNN model, has been developed to help physicians for automatic detection of MS lesions and monitoring of change. For the automatic detection of MS lesions, experimental studies are carried out on MSAkdeniz dataset and eHealth, UMCL, ISBI2015 and MICCAI2008 datasets on two different platforms, using five different deep learning models, primarily the proposed iMask R-CNN model, and the results are compared. Using the proposed iMask R-CNN, scores of  $88.32 \pm 4.44\%$  for Dice similarity coefficient (DSC) and  $89.80 \pm 3.54\%$  for lesion true positive rate (LTPR) are obtained in lesion detection datasets. With the proposed iMask R-CNN and DeepMSWeb, assistant tools that can be used in the detection and monitoring of MS lesions have been developed.

**Keywords:** Multiple Sclerosis, Lesion Detection, Follow-up, Deep Learning, Mask R-CNN, Decision Support System

# İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	i
ÖZET.....	iii
ABSTRACT.....	iv
İÇİNDEKİLER.....	v
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	x
GRAFİKLER LİSTESİ.....	xiv
KISALTMALAR LİSTESİ.....	xvii
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	6
1.2. Tezin Organizasyonu.....	6
2. KAPSAMLI LİTERATÜR TARAMASI.....	8
3. MULTİPL SKLEROZ.....	20
3.1. MS'de Epidemiyoloji (Kimlerde Görülür ve Görülme Sıklığı).....	20
3.2. MS'de Etimoloji (Nedenleri ve Belirtileri).....	21
3.3. MS Tanısının Konulması.....	22
3.4. MS Türleri.....	24
3.5. MR Görüntüleme ile MS Teşhisi.....	26
4. MS LEZYONLARININ MR GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME YÖNTEMLERİ İLE OTOMATİK TESPİTİ.....	29
4.1. Materyal ve Yöntem.....	30
4.1.1. Verisetleri.....	30
4.1.1.1. MSAkdeniz Veriseti.....	30
4.1.1.2. eHealth Laboratuvarı MS Veriseti.....	31
4.1.1.3. Ljubljana Üniversitesi UMCL Veriseti.....	32
4.1.1.4. ISBI 2015 Veriseti.....	33
4.1.1.5. MICCAI2008 MS Lezyon Bölütleme Veriseti.....	34
4.1.2. Etiketlerin Organizasyonu ve Düzenlemesi.....	35
4.1.3. Veri Arttırma (Data Augmentation).....	37
4.1.4. Derin Öğrenme Platformları.....	37
4.1.4.1. Tensorflow 2.0 ve Keras.....	38
4.1.4.2. PyTorch ve Detectron2.....	39
4.1.5. Derin Öğrenme Modelleri.....	39
4.1.5.1. Mask R-CNN.....	41

4.1.5.2. ResNet ve ResNeXt Omurga Yapıları.....	42
4.1.5.1. U-Net .....	44
4.1.6.iMask R-CNN ve Lezyon Tespit Süreci.....	45
4.2. Deneysel Sonuçlar .....	49
4.3. Verisetlerinin Organizasyonu .....	50
4.4. Performans Ölçüm Metrikleri.....	51
4.5. Derin Öğrenme Modellerinin Organizasyonu .....	55
4.6. MSAkdeniz Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar .....	57
4.6.1.MSAkdeniz Verisetinde U-Net ile Elde Edilen Sonuçlar .....	57
4.6.2.MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	61
4.6.3.MSAkdeniz Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	64
4.6.4.MSAkdeniz Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonuçlar .....	65
4.6.5.MSAkdeniz Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar ..	68
4.6.6.MSAkdeniz Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi .....	72
4.7. eHealth Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar .....	72
4.7.1.eHealth Verisetinde U-Net ile Elde Edilen Sonuçlar .....	72
4.7.2.eHealth Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	76
4.7.3.eHealth Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	77
4.7.4.eHealth Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonuçlar .....	81
4.7.5.eHealth Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar .....	82
4.7.6.eHealth Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi .....	86
4.8. UMCL Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar .....	86
4.8.1.UMCL Verisetinde U-Net ile Elde Edilen Sonuçlar .....	86
4.8.2.UMCL Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	90
4.8.3.UMCL Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	91
4.8.4.UMCL Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonuçlar .....	95
4.8.5.UMCL Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar .....	96
4.8.6.UMCL Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi .....	100
4.9. ISBI2015 Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar.....	100
4.9.1.ISBI2015 Verisetinde U-Net ile Elde Edilen Sonuçlar .....	100
4.9.2.ISBI2015 Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	104
4.9.3.ISBI2015 Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar .....	105
4.9.4.ISBI2015 Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonuçlar.....	107
4.9.5.ISBI2015 Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar.....	111
4.9.1.ISBI2015 Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi .....	112
4.10. MICCAI2008 Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar.....	114
4.10.1.MICCAI2008 Verisetinde U-Net ile Testler ve Elde Edilen Sonuçlar.....	114

4.10.1. MICCAI2008 Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonular	116
4.10.2. MICCAI2008 Veriseti ile iMask R-CNN-R101-K ile Elde Edilen Sonular	118
4.10.3. MICCAI2008 Veriseti ile iMask R-CNN-R101-D ile Elde Edilen Sonular	121
4.10.4. MICCAI2008 Veriseti ile iMask R-CNN-RX101-D ile Elde Edilen Sonular	123
4.10.5. MICCAI2008 Veriseti Üzerindeki Eğitim ve Testlerin Deęerlendirmesi ....	127
4.11. MS Lezyonlarının Tespit Sürecinde Kullanılan Modellerin Karşılaştırmalı Deęerlendirmesi.....	127
<b>5. MS LEZYONLARINDAKİ DEęİŐİMİN TAKİBİ İİN DERİN ÖęRENME TABANLI BİR KARAR DESTEK SİSTEMİNİN GELİŐTİRİLMESİ.....</b>	<b>129</b>
5.1. Materyal ve Yöntem .....	130
5.1.1. eHealth Veriseti.....	130
5.1.2. Derin Öęrenme Ortamı ve Model .....	131
5.1.3. Flask Çatısı.....	131
5.1.4. Arayüz Araları .....	131
5.1.5. ÖrtüŐme Tespit Algoritması .....	131
5.2. DeepMSWeb KDS'nin Alt Yapısı .....	133
5.3. DeepMSWeb KDS Kullanılarak MS Lezyonlarının Tespiti Sistemi .....	134
5.3.1. Tespit İin Veri GiriŐ Formu .....	135
5.3.1. MS Lezyonları Tespit Sisteminin Sonularının Gösterimi .....	136
5.3.1. DeepMSWeb KDS ile MS Lezyonu Tespit Örnekleri .....	137
5.4. DeepMSWeb KDS Kullanılarak MS Lezyonlarının DeęiŐimin Takibi Sistemi....	140
5.4.1. Takip Sisteminin Veri GiriŐ Formu .....	140
5.4.1. Takip Sisteminin Sonularının Gösterimi.....	141
5.4.1. DeepMSWeb KDS ile MS Lezyon Takip Örneęi.....	144
5.5. DeepMSWeb Uygulamasının Özellikleri .....	147
5.1. DeepMSWeb KDS'nin Deęerlendirmesi .....	147
<b>6. TARTIŐMA.....</b>	<b>149</b>
<b>7. SONU .....</b>	<b>169</b>
<b>KAYNAKLAR.....</b>	<b>173</b>

## TABLULAR LİSTESİ

### Sayfa No

<b>Tablo 2.1.</b> Literatürde MS Tespiti İçin Temel Görüntü İşleme Algoritmalarını Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri.....	10
<b>Tablo 2.2.</b> Literatürde MS Tespiti İçin Yapay Zekâ Algoritmalarını Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri .....	12
<b>Tablo 2.3.</b> Literatürde MS Tespiti için Derin Öğrenme Modellerini Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri I .....	13
<b>Tablo 2.4.</b> Literatürde MS Tespiti İçin Derin Öğrenme Modellerini Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri II.....	16
<b>Tablo 2.5.</b> Literatürde Öne Çıkan MS Alanında Önerilen KDS Uygulamaları ile İlgili Bazı Çalışmalar ve Değerlendirmeleri .....	19
<b>Tablo 3.1.</b> MS Hastalığı Başlangıcındaki Belirtiler ve Görülme Sıklıkları.....	22
<b>Tablo 3.2.</b> Mcdonald Kriterleri 2017 .....	24
<b>Tablo 4.1.</b> Deneysel Çalışmalar İçin Kullanılan Bilgisayarın Konfigurasyon Özellikleri.....	50
<b>Tablo 4.2.</b> Performans Ölçütlerinin Hesaplanmasında Kullanılan Karmaşıklık Matrisi.....	52
<b>Tablo 4.3.</b> Mask R-CNN ve iMask R-CNN Mimarileri İçin Belirlenen Spesifik Ayarlar.....	55
<b>Tablo 4.4.</b> Detectron 2 ile Mask R-CNN Modelinin Uygulanması İçin Belirlenen Spesifik Ayarlar.....	56
<b>Tablo 4.5.</b> Tez Kapsamında Kullanılan Derin Öğrenme Modellerinin Kısa İsimleri .....	57
<b>Tablo 4.6.</b> MSAkdeniz Verisetinin U-Net ile Alınan En İyi Tur Sonuçları .....	59
<b>Tablo 4.7.</b> MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Elde Edilen En İyi Tur Sonuçları .....	62
<b>Tablo 4.8.</b> MSAkdeniz Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları	65
<b>Tablo 4.9.</b> MSAkdeniz Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları	68
<b>Tablo 4.10.</b> MSAkdeniz Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları .....	70
<b>Tablo 4.11.</b> MSAkdeniz Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu.....	72
<b>Tablo 4.12.</b> eHealth Verisetinin U-Net ile Alınan En İyi Tur Sonuçları.....	74
<b>Tablo 4.13.</b> eHealth Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .....	77
<b>Tablo 4.14.</b> eHealth Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .....	79
<b>Tablo 4.15.</b> eHealth Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları .....	82
<b>Tablo 4.16.</b> eHealth Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları ..	84
<b>Tablo 4.17.</b> eHealth Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu.....	86
<b>Tablo 4.18.</b> UMCL Verisetinin U-Net ile Alınan En İyi Tur Sonuçları.....	88
<b>Tablo 4.19.</b> UMCL Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .....	91

<b>Tablo 4.20.</b> UMCL Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .....	93
<b>Tablo 4.21.</b> UMCL Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları .....	96
<b>Tablo 4.22.</b> UMCL Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları ...	98
<b>Tablo 4.23.</b> UMCL Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu.....	100
<b>Tablo 4.24.</b> ISBI2015 Verisetinin U-Net ile Alınan En İyi Tur Sonuçları.....	102
<b>Tablo 4.25.</b> ISBI2015 Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .	105
<b>Tablo 4.26.</b> ISBI2015 Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları	109
<b>Tablo 4.27.</b> ISBI2015 Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları .....	112
<b>Tablo 4.28.</b> ISBI2015 Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu.....	112
<b>Tablo 4.29.</b> MICCAI2008 Verisetinin U-Net ile Alınan En İyi Tur Sonuçları.....	115
<b>Tablo 4.30.</b> MICCAI2008 Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .....	118
<b>Tablo 4.31.</b> MICCAI2008 Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları .....	120
<b>Tablo 4.32.</b> MICCAI2008 Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları .....	123
<b>Tablo 4.33.</b> MICCAI2008 Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları .....	125
<b>Tablo 4.34.</b> MICCAI2008 Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu.....	127
<b>Tablo 4.35.</b> Modellerin Karşılaştırma Tablosu.....	128
<b>Tablo 5.1.</b> Lezyon Karşılaştırmasında Skorları Belirleyen Algoritmanın Pseudo Kodu .....	133
<b>Tablo 5.2.</b> DeepMSWeb-KDS'nin Takip Sistemi Sonuç Raporu Örneği .....	145
<b>Tablo 6.1.</b> eHealth Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması.....	156
<b>Tablo 6.2.</b> UMCL Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması.....	158
<b>Tablo 6.3.</b> ISBI2015 Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması.....	161
<b>Tablo 6.4.</b> MICCAI2008 Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması.....	167

## ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1. WoS üzerinde “ <i>multiple sclerosis mri segmentation</i> ” için alınan geri dönütlerin bibliyografik ilişki ağı grafiği .....	8
Şekil 3.1. MS Tiplerinin Geçişleri ve İlişkileri Grafiği .....	25
Şekil 3.2. MS Kesitlerinde (a)PD (b)T2w (c)FLAIR Sekanslarında MS Lezyonları .....	27
Şekil 3.3. Farklı Açılardan, (a) Aksiyel, (b) Koronal, (c) Sagittal MR Kesit Örnekleri.....	27
Şekil 3.4. Çeşitli Beyin Hasarlarına Ait MR Görüntüleri .....	28
Şekil 4.1. Tez Kapsamında Önerilen Otomatik MS Lezyon Tespit Yaklaşımının Açık Blok Diyagramı.....	29
Şekil 4.2. MS Akdeniz Verisetinden Sagittal (A1, B1), Aksiyel (A2, B2) ve Koronal (A3, B3) Açıdan Örnek MR Görüntüleri .....	31
Şekil 4.3. eHealth Laboratuvarı MS Verisetinden Örnek MR Görüntüleri. (A, B, C) Farklı Hasta Taramaları. (A1-B1-C1) Hastaların İlk MR Tarama Görüntüleri, (A2-B2-C2) ise Aynı Hastaların 6 veya 12 Aylık Periyodik Muayenesinden Alınan Yakın Noktanın MR Görüntüleri .....	32
Şekil 4.4. UMCL Verisetinden Alınan ve (A, B, C) ile Farklı Hastaların Temsil Edildiği Sırayla Aksial (A1-B1-C1), Koronal (A2-B2-C2) ve Sagittal (A3-B3-C3) Düzlemde MR Kesit Örnekleri.....	33
Şekil 4.5. ISBI2015 Verisetinden Alınan, A ve B ile Farklı Hastaların Temsil Edildiği Aynı Çekimdeki Farklı MR Görüntüleri .....	34
Şekil 4.6. MICCAI2008 Verisetinden UNC Tarafından Alınan Farklı Hastaların (A1-B1-C1) ve CHB Tarafından Alınan Farklı Hastaların (A2-B2-C2) MR Görüntüleri .....	35
Şekil 4.7. .plq Uzantılı Dosyalarının VGG Formatına Uyumlu JSON’a Çevrilmesi .....	36
Şekil 4.8. VGG Image Annotator ile MS Lezyon Etiketleme Prosedürleri.....	36
Şekil 4.9. MS Akdeniz(a), eHealth(b), UMCL(c), ISBI2015(d) ve MICCAI2008(e) Verisetlerinde Veri Artırımı Yapıldığında Elde Edilen Örnek MR Görüntüleri .....	38
Şekil 4.10. Tensorflow ve Keras Platformunun Donanım ile İlişkisi .....	39
Şekil 4.11. Standart CNN Yapısının Katmanlı Örnek Gösterimi .....	40
Şekil 4.12. Mask R-CNN Mimarisinin Genel Yapısı .....	42
Şekil 4.13. ResNet Mimarisinin Genel Blok Yapısı .....	43
Şekil 4.14. 32x8d ResNeXt Omurgasının Blok Yapısı.....	44
Şekil 4.15. U-Net Derin Öğrenme Modelinin Mimari Yapısı .....	45
Şekil 4.16. Tez Kapsamında Önerilen iMask R-CNN Mimarisinin Yapısı.....	46
Şekil 4.17. (a) Standart RoI Tespit Yapısı, (b, c, d) İyileştirilmiş RoI Tespit Yapısı .....	47
Şekil 4.18. MS Lezyon Tespitinde Tüm Görüntü Üzerinde Yapılan Maskeleyme İşlemi Adımları .....	48

<b>Şekil 4.19.</b> MS Lezyon Tespitinde Bir Lezyonun Tespiti İçin Yapılan İşlem Süreci.....	49
<b>Şekil 4.20.</b> MSAkdeniz Verisetinde MR Görüntüleri ve Uzmanlar Tarafından Belirlenmiş Lezyon Maskelerinin Veri Arttırma Sonucu Üretilen Versiyonları.....	58
<b>Şekil 4.21.</b> MSAkdeniz Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi.....	60
<b>Şekil 4.22.</b> MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri .....	63
<b>Şekil 4.23.</b> MSAkdeniz Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri .....	66
<b>Şekil 4.24.</b> MSAkdeniz Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri .....	69
<b>Şekil 4.25.</b> MSAkdeniz Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri .....	71
<b>Şekil 4.26.</b> eHealth Verisetinin Veri Arttırma Sonucu Üretilen MR ve Lezyon Maskeleri ....	73
<b>Şekil 4.27.</b> eHealth Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi.....	75
<b>Şekil 4.28.</b> eHealth Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	78
<b>Şekil 4.29.</b> eHealth Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	80
<b>Şekil 4.30.</b> eHealth Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	83
<b>Şekil 4.31.</b> eHealth Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	85
<b>Şekil 4.32.</b> UMCL Verisetinin Veri Arttırma İşlemi ile Elde Edilmiş MR Görüntülerine ve Lezyon Maskeleri.....	87
<b>Şekil 4.33.</b> UMCL Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi.....	89
<b>Şekil 4.34.</b> UMCL Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	92
<b>Şekil 4.35.</b> UMCL Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	94
<b>Şekil 4.36.</b> UMCL Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	97
<b>Şekil 4.37.</b> UMCL Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	99

<b>Şekil 4.38.</b> ISBI2015 Verisetinin Veri Arttırma Sonucu Üretilen MR ve Lezyon Maskeleri Örnekleri.....	101
<b>Şekil 4.39.</b> ISBI2015 Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi.....	103
<b>Şekil 4.40.</b> ISBI2015 Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	106
<b>Şekil 4.41.</b> ISBI2015 Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntülerine Örnekler.....	108
<b>Şekil 4.42.</b> ISBI2015 Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	110
<b>Şekil 4.43.</b> ISBI2015 Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	113
<b>Şekil 4.44.</b> MICCAI2008 Verisetinin Veri Arttırma Sonucu Üretilen MR ve Lezyon Maskeler .....	114
<b>Şekil 4.45.</b> MICCAI2008 Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi.....	117
<b>Şekil 4.46.</b> MICCAI2008 Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntülerine Örnekler.....	119
<b>Şekil 4.47.</b> MICCAI2008 Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	122
<b>Şekil 4.48.</b> MICCAI2008 Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	124
<b>Şekil 4.49.</b> MICCAI2008 Verisetinde iMask Mask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri.....	126
<b>Şekil 5.1.</b> MS Lezyonlarının Tespiti İçin Önerilen DeepMSWeb Mimarisinin Açık Blok Diyagramı.....	129
<b>Şekil 5.2.</b> eHealth Verisetinden Aynı Hastanın (a) İlk MR Çekiminden, (b) İkinci Muayenedeki MR Çekiminden Alınan Bazı Örnek Kesitler .....	130
<b>Şekil 5.3.</b> DeepMSWeb ile MS Lezyonlarındaki Değişim Tespitinin İncelenmesi Sırasında İncelenen İki MR Kesitinin Örtüşmesini Değerlendiren ÖTA Yapısı.....	132
<b>Şekil 5.4.</b> DeepMSWeb Uygulamasının Kullanıcı Durum Diyagramı.....	134
<b>Şekil 5.5.</b> MS Lezyonlarının Otomatik Tespiti İçin Bu Çalışmada Geliştirilen DeepMSWeb Web Uygulamanın Karşılama/Anasayfası .....	134
<b>Şekil 5.6.</b> DeepMSWeb Üzerinde MS Lezyonlarının Otomatik Tespiti İçin MR Kesitini ve Uzman Maskesi Dosyasını Yükleme Sayfası.....	135
<b>Şekil 5.7.</b> DeepMSWeb Üzerinde MS Lezyonlarının Otomatik Tespiti İçin MR Kesitini ve Uzman Görüşü Dosyasını Yükleme Sayfasının Ön İzleme Yapan Hali .....	136
<b>Şekil 5.8.</b> DeepMSWeb'e Sadece MR Kesiti Yüklendiği Zaman Görülen Sonuç Sayfası ...	137

<b>Şekil 5.9.</b> DeepMSWeb Kullanılarak MR Görüntüleri Üzerinde MS Lezyonlarının Otomatik Tespiti ve Sonuçların Karşılaştırılması .....	138
<b>Şekil 5.10.</b> DeepMSWeb Üzerinden KDS'nin Tespit Sisteminin Sonuç Örnekleri .....	139
<b>Şekil 5.11.</b> DeepMSWeb Uygulamasında Takip Sistemine MR Görüntülerinin ve json Dosyalarının Yüklendiği Form Sayfası .....	140
<b>Şekil 5.12.</b> DeepMSWeb Uygulamasında Takip Sistemine MR Görüntülerinin ve json Dosyalarının Yüklendiği Form Sayfasının Ön İzleme Ekranı .....	141
<b>Şekil 5.13.</b> Takip Sisteminde Otomatik Lezyon Tespiti İçin Sonuç Ekranı .....	142
<b>Şekil 5.14.</b> Takip Sisteminde Karşılaştırmalı Otomatik MS Lezyonu Tespit İçin Sonuç Ekranı (Birinci Bölüm) .....	143
<b>Şekil 5.15.</b> Takip Sisteminde Karşılaştırmalı Otomatik MS Lezyonu Tespit İçin Sonuç Ekranı (İkinci Bölüm) .....	144
<b>Şekil 5.16.</b> DeepMSWeb Üzerinden KDS'nin Takip Sistemi Sonuç Örneği .....	146
<b>Şekil 5.17.</b> MR Görüntüsünün Tam Ekran Görünümü .....	147
<b>Şekil 5.18.</b> DeepMSWeb Takip Sisteminin Farklı Ekran Boyutlarında Görünümü (a) Cep Telefonunda Görünüm, (b) Tablet Ortamında Görünüm .....	148
<b>Şekil 6.1.</b> MSAkdeniz Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntüler .....	152
<b>Şekil 6.2.</b> eHealth Verisetinden Bir Örnek MR Kesiti ve MS Lezyonları .....	153
<b>Şekil 6.3.</b> eHealth Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntüler .....	155
<b>Şekil 6.4.</b> UMCL Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntü Örnekleri .....	159
<b>Şekil 6.5.</b> ISBI2015 Verisetinin Ön İşlem Yapılmış MR Kesiti Örneği (a) Ön İşlem Yapılmamış MR Kesiti, (b) Ön İşlem Yapılmış MR Kesiti .....	160
<b>Şekil 6.6.</b> ISBI2015 Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntü Örnekleri .....	163
<b>Şekil 6.7.</b> MICCAI2008 Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntüler .....	166

## GRAFİKLER LİSTESİ

Sayfa No

<b>Grafik 4.1.</b> MSAkdeniz Verisetinde U-Net ile Eğitim Sürecinde Hata Değişim Grafiği .....	58
<b>Grafik 4.2.</b> MSAkdeniz Verisetinde U-Net ile Yapılan Testlerinin DSC Değişimi .....	59
<b>Grafik 4.3.</b> MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Yapılan Eğitim Sürecindeki Hata Değişim Grafiği .....	61
<b>Grafik 4.4.</b> MSAkdeniz Veriseti ile Mask R-CNN-R101-K Üzerinde Yapılan Testlerin DSC Değişimi .....	62
<b>Grafik 4.5.</b> MSAkdeniz Verisetinde iMask R-CNN-R101-K ile Yapılan Eğitim Sürecindeki Hataların Değişim Grafiği.....	64
<b>Grafik 4.6.</b> MSAkdeniz Veriseti ile Mask R-CNN-R101-K Üzerinde Yapılan Testlerin DSC Değişimi .....	64
<b>Grafik 4.7.</b> MSAkdeniz Verisetinde iMask R-CNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği .....	67
<b>Grafik 4.8.</b> MSAkdeniz Verisetinin iMask R-CNN-R101-D Üzerinde Yapılan Testlerin DSC Değişimi .....	67
<b>Grafik 4.9.</b> MSAkdeniz Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Hata Değişim Grafiği .....	68
<b>Grafik 4.10.</b> MSAkdeniz Verisetinde iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların Testlerdeki DSC Değişimi.....	70
<b>Grafik 4.11.</b> eHealth Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği.....	73
<b>Grafik 4.12.</b> eHealth Veriseti ile U-Net Üzerinde Yapılan Testlerinin DSC Değişiminin Grafiği .....	74
<b>Grafik 4.13.</b> eHealth Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği .....	76
<b>Grafik 4.14.</b> eHealth Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi.....	76
<b>Grafik 4.15.</b> eHealth Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği .....	77
<b>Grafik 4.16.</b> eHealth Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi.....	79
<b>Grafik 4.17.</b> eHealth Verisetinin iMask R-CNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği .....	81
<b>Grafik 4.18.</b> eHealth Verisetinin iMask R-CNN-R101-D Eğitim Sürecin DSC Değişim Grafiği .....	81
<b>Grafik 4.19.</b> eHealth Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Grafiği .....	82
<b>Grafik 4.20.</b> eHealth iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin DSC Değişimi.....	84
<b>Grafik 4.21.</b> UMCL Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği .....	87

<b>Grafik 4.22.</b> UMCL Veriseti Üzerinde Yapılan U-Net Testlerinin DSC Benzerlik Değişimi	88
<b>Grafik 4.23.</b> UMCL Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği	90
<b>Grafik 4.24.</b> UMCL Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi	90
<b>Grafik 4.25.</b> UMCL Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği	91
<b>Grafik 4.26.</b> UMCL Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi	93
<b>Grafik 4.27.</b> UMCL Verisetinin iMask R-CNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği	95
<b>Grafik 4.28.</b> UMCL Verisetinin iMask R-CNN-R101-D Testlerinde DSC Değişim Grafiği	95
<b>Grafik 4.29.</b> UMCL Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Grafiği	96
<b>Grafik 4.30.</b> UMCL Verisetinin iMask R-CNN-RX101-D Eğitim Sürecin DSC Değişim Grafiği	98
<b>Grafik 4.31.</b> ISBI2015 Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği	101
<b>Grafik 4.32.</b> ISBI2015 Veriseti ile U-Net Üzerinde Yapılan Testlerinin DSC Değişiminin Grafiği	102
<b>Grafik 4.33.</b> ISBI2015 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği	104
<b>Grafik 4.34.</b> ISBI2015 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi	104
<b>Grafik 4.35.</b> ISBI2015 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği	105
<b>Grafik 4.36.</b> ISBI2015 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi	107
<b>Grafik 4.37.</b> ISBI2015 Verisetinin iMask RCNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği	107
<b>Grafik 4.38.</b> ISBI2015 Verisetinin iMask R-CNN-R101-D Eğitim Sürecin DSC Değişimi	109
<b>Grafik 4.39.</b> ISBI2015 Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Hata Değişimi	111
<b>Grafik 4.40.</b> ISBI2015 Verisetinin iMask R-CNN-RX101-D Eğitim Sürecin DSC Değişim Grafiği	111
<b>Grafik 4.41.</b> MICCAI2008 Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği	115
<b>Grafik 4.42.</b> MICCAI2008 Veriseti ile U-Net Üzerinde Yapılan Testlerinin DSC Değişiminin Grafiği	115
<b>Grafik 4.43.</b> MICCAI2008 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği	116
<b>Grafik 4.44.</b> MICCAI2008 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi	118

<b>Grafik 4.45.</b> MICCAI2008 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği .....	120
<b>Grafik 4.46.</b> MICCAI2008 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi .....	120
<b>Grafik 4.47.</b> MICCAI2008 Verisetinin iMask R-CNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği .....	121
<b>Grafik 4.48.</b> MICCAI2008 Verisetinin iMask R-CNN-R101-D Eğitim Sürecin DSC Değişimi .....	121
<b>Grafik 4.49.</b> MICCAI2008 Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Grafiği .....	123
<b>Grafik 4.50.</b> MICCAI2008 Verisetinin iMask R-CNN-RX101-D Eğitim Sürecin DSC Değişim Grafiği .....	125
<b>Grafik 6.1.</b> MSAkdeniz Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması.....	151
<b>Grafik 6.2.</b> eHealth Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması.....	154
<b>Grafik 6.3.</b> UMCL Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması.....	157
<b>Grafik 6.4.</b> ISBI2015 Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması.....	162
<b>Grafik 6.5.</b> MICCAI2008 Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması.....	165

## KISALTMALAR LİSTESİ

<b>A<sub>gt</sub></b>	: Uzman Tarafından Lezyon Olan Tanımlanmış Alan
<b>A<sub>seg</sub></b>	: Önerilen Model ile Belirlenmiş Seçim Alanı
<b>ASD</b>	: Ortalama Simetrik Yüzey Mesafesi (Average Symmetric Surface Distance)
<b>B</b>	: Boyut
<b>BOS</b>	: Beyin Omurilik Sıvısı
<b>CNN</b>	: Evrişimsel Sinir Ağı (Convolutional Neural Network)
<b>CSF</b>	: Beyin Omurilik Sıvısı Analizi (Colony Stimulating Factor)
<b>CSS</b>	: Basamaklı Stil Şablonları (Cascading Style Sheets)
<b>DeepScan</b>	: Taramalı Derin Öğrenme
<b>DSC</b>	: Dice Benzerlik Katsayısı (Dice Similarity Coefficient)
<b>DSÖ</b>	: Dünya Sağlık Örgütü
<b>DVM</b>	: Destek Vektör Makineleri
<b>Fast R-CNN</b>	: Hızlı Bölge Tabanlı Evrişimsel Sinir Ağı
<b>Faster R-CNN</b>	: Daha Hızlı Bölge Tabanlı Evrişimsel Sinir Ağı
<b>FLAIR</b>	: Sıvı ile Zayıflatılmış Ters Çevirme Geri Kazanımlı (Fluid-Attenuated Inversion Recovery)
<b>FN</b>	: Yanlış Negatif (False Negative)
<b>FP</b>	: Yanlış Pozitif (False Positive)
<b>HD95</b>	: Hausdorff Mesafesi (Hausdorff Distance 95)
<b>HTML</b>	: Hiper Metin İşaretleme Dili (Hypertext Markup Language)
<b>iMask R-CNN</b>	: İyileştirilmiş Maskeli Bölge Tabanlı Evrişimsel Sinir Ağı
<b>iMask R-CNN</b>	: İyileştirilmiş Maskeli Bölge Tabanlı Evrişimsel Sinir Ağı
<b>iMask R-CNN-R101-D</b>	: ResNet101 Omurga Yapısını Kullanarak Detectron2 Ortamında Çalışan İyileştirilmiş Maskeli Bölge Tabanlı Evrişimsel Sinir Ağı

<b>iMask R-CNN-R101-K</b>	: ResNet101 Omurga Yapısını Kullanarak Keras Ortamında Çalışan İyileştirilmiş Maskeli Bölge Tabanlı Evrişimsel Sinir Ağı
<b>iMask R-CNN-RX101-D</b>	: ResNeXt101 Omurga Yapısını Kullanarak Detectron2 Ortamında Çalışan İyileştirilmiş Maskeli Bölge Tabanlı Evrişimsel Sinir Ağı
<b>JSC</b>	: Jaccard Benzerlik Katsayısı (Jaccard Coefficient Similarity)
<b>KDS</b>	: Karar Destek Sistemi
<b>KIS</b>	: Klinik İzole Sendrom (Clinically Isolated Syndrome- CIS)
<b>k-NN</b>	: En Yakın Komşu Algoritması
<b>Level Set</b>	: Düzey Ayarlama
<b>LFPR</b>	: Lezyon Yanlış Tespit Oranı (Lesion False Positive Rate)
<b>LTPR</b>	: Lezyon Doğru Tespit Oranı (Lesion True Positive Rate)
<b>Mask R-CNN</b>	: Maskeli Bölge Tabanlı Evrişimsel Sinir Ağı
<b>MR</b>	: Manyetik Rezonans
<b>MRG</b>	: Manyetik Rezonans Görüntüleme
<b>MS</b>	: Multipl Skleroz
<b>MSS</b>	: Merkezi Sinir Sistemi
<b>Multi-View L-CNN</b>	: Çok Katmanlı Uzamsal CNN
<b>OKB</b>	: Oligoklonal Bant
<b>ÖTA</b>	: Örtüşme Tespit Algoritması
<b>PCA</b>	: Temel Bileşen Analizi (Principal Component Analysis)
<b>PPMS</b>	: Birincil İlerleyici Multipl Skleroz (Primer Progressive MS)
<b>PRE</b>	: Kesinlik (Precision)
<b>PreLU</b>	: Parametrik Rektifiye Doğrusal Ünite
<b>PRMS</b>	: Yenileyici İlerleyici Multipl Skleroz (Progressive Relapsing MS)
<b>PYa</b>	: Proton Yoğunluklu (Proton Density, PD)
<b>RC</b>	: Duyarlılık (Recall)
<b>R-CNN</b>	: Bölge Tabanlı Evrişimsel Sinir Ağı (Region Based CNN)

<b>ReLu</b>	: Rektifiye Doğrusal Ünite
<b>RoI</b>	: Tahmini Önemli Bölge (Region of Interest)
<b>RPN</b>	: Bölge Teklif Ağı (Region Proposal Network)
<b>RRMS</b>	: Yineleyici Düzelen Multipl Skleroz (Relapsing Remitting MS)
<b>RVD</b>	: Göreceli Hacim Farkı (Relative Volume Difference)
<b>SEP</b>	: Beyin ve Omurilik Bölgesi Dışında Kalan Sinir Bölgelerinin Uyarılması ile Kayıtlanan Potansiyeller (Somatosensory Evoked Potentials)
<b>SLFP</b>	: segmentasyon sonucu lezyon olarak belirlenmiş ancak yanlış tespit edilen lezyon sayısı
<b>SLS</b>	: MR Kesiti Üzerinde Bulunan Referans Lezyon Sayısı
<b>SLTP</b>	: Doğru Tespit Edilen Lezyon Sayısını
<b>SPMS</b>	: İkincil İlerleyici Multipl Skleroz (Secunder Progressive MS)
<b>Sps</b>	: Segmentasyon Sonucunda Tespit Edilen Toplam Lezyon Sayısı
<b>T</b>	: Tesla
<b>T1a</b>	: T1 ağırlıklı (T1- weighted, T1w)
<b>T2a</b>	: T2 ağırlıklı (T2- weighted, T2w),
<b>TN</b>	: Doğru Negatif (True Negative)
<b>TP</b>	: Doğru Pozitif (True Positive)
<b>TPR</b>	: Doğru Pozitif Oranı (True Pozitive Rate)
<b>U-Net</b>	: U-Net Derin Öğrenme Modelinde Evrişimsel Sinir Ağı
<b>VOE</b>	: Alan Yoğunluk Farkı (Volumetric Overlap Error)
<b>WoS</b>	: Web of Science
<b>WTKDS</b>	: Web Tabanlı Karar Destek Sistemleri

## 1. GİRİŞ

Multipl skleroz (MS) beyni ve omuriliği etkileyen genç ve orta yaşlı insanlarda yaygın olarak görülen bir merkezi sinir sistemi (MSS, Central Nervous System (CNS)) hastalığıdır (Zahoor vd., 2021: 3181). Genç erişkinlerde travmatik olmayan nörolojik sakatlığın önde gelen nedenidir (Rush vd., 2015: 379). MS, MSS'nin ilerleyici hastalıklarından biridir ve beynin yapısını değiştirmektedir. Bu değişim, akson adı verilen nöronal lifleri saran yağlı madde olan miyelin kılıfın hasar alarak sinyallerin doğru iletilmemesine ve bu nedenle vücut fonksiyonlarının bozulmasına neden olmaktadır (Mortazavi vd., 2012: 300).

MS'in başlangıcı sinsi veya ani olabilir (Calabresi, 2004: 1935). Hastalık duyma, hareket becerisi, denge, kas işlevlerinde fonksiyon kaybı, görme ve bilişte değişikliklerle ortaya çıkabilmektedir (Brownlee vd., 2017: 389). Sıklıkla eşlik eden belirti ve semptomlar arasında mesane sıkışıklığı, kabızlık, cinsel işlev bozukluğu, yorgunluk, depresyon, çift görme, yürüme bozukluğu, uzuv-işlev bozukluğu, lhermitte belirtisi (boyun bölgesinden omurgada aşağı doğru elektriklenme hissi) bulunur (Calabresi, 2004: 1935).

MS'in nedeninin tam olarak belirlenemediği, genetik etkinin önemli bir unsur olduğu ve D vitamini eksikliğinin etkisinin olduğu bazı akademik çalışmalarda raporlanmıştır. Bu çalışmalardan birinde, MS'in oluşumuna genetik duyarlılık, bağışıklık sistemindeki anormallikler ve tetikleyici çevresel faktörlerin kesin olarak bilinmemekle birlikte neden olduğuna vurgulanmaktadır (Calabresi, 2004: 1936). Ayrıca, MS hastalığına aynı anda genetik ve çevresel risk faktörlerinin kümülatif birleşiminin neden olduğu da düşünülmektedir (Patsopoulos, 2018: 1). Yapılan bazı araştırmalara göre; tek yumurta ikizlerinde MS'e yakalanma oranı %4 ile %5 arasında olurken, bu oran çift yumurta ikizlerinde %2 ile %3 arasına kadar düşmektedir (Islam vd., 2006: 56). Bunun yanında, MS'e mevsimsel güneşin az görüldüğü yerlerde ortaya çıkan D vitamini eksikliğinin de neden olabileceği belirtilmiştir (Sintzel vd., 2018: 59). Buna karşın, bağışıklık sistemi hastalıkları ile MS arasında anlamlı bir ilişki de bulunamamıştır (Abdollahpour vd., 2019).

MS hastalığı dünya genelinde yaygın olan ve ileri evrelerinde ölümle sonuçlanabilen, teşhis ile tedavi süreçlerinin maliyeti yüksek bir hastalıktır. Dünya sağlık örgütünün (DSÖ) yayınladığı raporlara göre, MS hasta sayısı 2008 yılında 2.1 milyon, 2013 yılında 2.3 milyon ve 2020 yılında 2.8 milyona ulaşmıştır (Atlas, 2020: 6; Browne vd., 2014: 1022). Bu raporda, yaşayan her 3000 kişiden birinde MS hastalığı olduğu, her 5 dakikada bir kişiye MS teşhisi

konulduğu görülmektedir ve MS'e bağlı nörolojik sebeplerden yılda 20 bin kişinin yaşamını yitirdiğini ortaya koyulmaktadır (Atlas, 2020: 6).

Bilim dünyası MS hastalığının tespiti, takibi ve tedavisi ile ilgili birçok alanda çalışmalar yapmaktadır. Bu çalışmalardan birisine göre, Avrupa'da hasta başı maliyetler 22 800€ ile 57 500€ arasında olup, bu maliyetler hastalığın seyrine göre değişebilmektedir ve ortalama yıllık maliyet 40 000€ civarındadır (Kobelt vd., 2017: 1123; Paz-Zulueta vd., 2020: 1). Avustralya'da yapılan bir başka çalışmaya göre ise, bu bölgede MS hastalarının yıllık maliyeti 65 000\$'ı bulmaktadır (Palmer vd., 2013: 1). Bu verilerden anlaşılacağı üzere, MS hastalığının tedavisi ekonomik olarak hem hastaya hem de sağlık kuruluşlarına yük oluşturmaktadır. Bundan ötürü, maliyetler hastalığın seyrine göre değiştiği için erken tanı ile tedavi maliyetleri düşürülebileceği değerlendirilmektedir (Palmer vd., 2013: 2). Bu yüzden, MS'de erken tedavi en iyi strateji olarak kabul edilmektedir (Fernández vd., 2010). Dolayısıyla, MS hastalığının tespitinde, nitel ve daha hızlı klinik kararlara ihtiyaç olduğu açıktır (Nayak vd., 2017).

Beyinde sinir hücresi liflerini koruyan miyelin kılıfı yağ içerir ve suyu iter. MS nedeniyle miyelin kılıfın zarar gördüğü bölgelerde, yağ sıyrılır. Yağ kaybedildikçe bu alan daha fazla su tutar ve MR görüntüleme tipine bağlı olarak açık beyaz bir nokta veya lezyonlar olarak görülür (Shoeibi vd., 2021). MS hastalığının (lezyonlarının) tanısını koyabilmek için hekimler McDonald kriterlerini kullanmaktadır (Thompson vd., 2018: 162). Bu kriterlere göre MS tanısı öncelikle klinik semptomlara bağlı olarak değerlendirilmektedir. Ayrıca, MR görüntülerinde beyaz cevher lezyonlarının incelenmesi ve nörolojik semptomlar görülmesi de MS ile ilişkilidir (Huang vd., 2017: 3164). MS'in teşhisinde hekimler öncelikle fiziksel muayene ve nörolojik hastalık hikayesi incelemesi yapmaktadır. Bunun yanında beyin ve omurilik bölgesi dışında kalan sinir bölgelerinin uyarılması ile kayıtlanan potansiyellerden (somatosensory evoked potentials - SEP), beyin omurilik sıvısı analizi (colony stimulating factor - CSF) sonuçlarından ve manyetik rezonans (MR) görüntülerinden yararlanılmaktadır (Hosseini vd., 2020: 612). Ancak MS lezyonları görsel olarak MR kesitlerinden ayrıştırılabilmesi ve lezyonun hangi hastalıkla ilişkili olduğuna dair kesin bilgi MR görüntülerinin incelenmesi ile anlaşılabilir (Cavaliere vd., 2019: 2).

Önceki çalışmalar incelendiğinde MS hastalığının MR gibi girişimsel olmayan (non-invazif) bir yöntemle doğru teşhisi, hastaların tedavilerinin planlamasında oldukça önemlidir (Ge, 2006: 1165; Rovira & León, 2008: 410). MS lezyonlarının tespiti için MR görüntüleme uzun yıllardır kullanılmaktadır (Polman vd., 2011: 841; Reynolds vd., 2011: 155). MS

hastalarının yaklaşık %95’inde MR görüntüleri üzerindeki lezyon alanları açıkça görülmektedir ve teşhis kolaylaşmaktadır (Paty vd., 1988: 180). Bunun yanında, MR görüntüleri MS tanısı sürecinde, MS’in diğer beyin hastalıklarından ayrıştırılmasına da yardımcı olmaktadır (Geraldde vd., 2018: 199). MR görüntülerinde, MS hastalığı nöromiyelitis optika (Lana-Peixoto vd., 2018: 53), akut serebral enfarktüs (Deguchi vd., 2018: 1033), akut yayılmış ensefalomyelit (Desse vd., 2018: 1789) gibi diğer beyaz cevher hastalıkları ile de karıştırılabilmektedir (Scolding, 2001: 1).

MS hastalığının tedavi sürecinde de tanı sürecinde olduğu gibi MR görüntülerinin kullanılması ve doğru yorumlanması büyük önem arz etmektedir. MS’in teşhis sürecinde, ilerlemesini takibinde ve tedaviye yanıtın izlenmesinde de MR görüntüleme rutin olarak kullanılmaktadır (Chawla vd., 2018: 2). Hekimler MR görüntüleme tekniklerinde farklı sekanslar kullanarak lezyon alanlarını farklı açılardan belirlemeye çalışmaktadır (Wadhwa vd., 2019: 247). MS teşhisi için genellikle MR görüntüleme cihazları ile T1 ağırlıklı (T1a, T1-weighted, T1w), T2 ağırlıklı (T2a, T2-weighted, T2w), 2 Boyutlu (2B) sıvı ile zayıflatılmış ters çevirme geri kazanımlı (Fluid-attenuated inversion recovery, FLAIR) ve 3B FLAIR sekanslarında çekim yapabilmektedir. Bu sekanslar çekim için özel sıvı verilmesi, cihazın çekim tekniklerinin/parametrelerinin değiştirilmesi gibi farklılıklar ile gerçekleşmektedir. Farklı MR sekansları ile önceden var olan ve yeni oluşan lezyonlar ayırt edilebilmektedir (Kitajima vd., 2012: 923). Bunun yanında, MS lezyonlarının tespiti çalışmalarında T2 sekanslarında alınan MR görüntü kesitlerinin sıklıkla kullanıldığı görülmektedir (Filippi & Rocca, 2007: 4; Kearney vd., 2015: 2; Weier vd., 2012: 1560). Ancak son yıllarda yapılan araştırmalar sonucunda sıkça kullanılmaya başlanan 3B FLAIR sekansının, 2B FLAIR ve T2 sekanslarına göre daha fazla lezyon alanını görüntülediği tespit edilmiştir (Farges vd., 2021: 702). Bunun yanında, MS lezyonlarının T2w ve FLAIR MR görüntüleri kullanılarak daha kesin olarak tespit edilebildiği görülmektedir (Geraldde vd., 2018: 209) Ayrıca, bu süreçte bir radyolog hekim tarafından el yordamı (manuel) MR görüntüsü incelenerek lezyonların sınırlarının seçilmesi sonucu MS tanısı gerçekleştirilmektedir (Shanmuganathan vd., 2020: 333).

Hekimlerin el yordamı ile lezyon belirleme süreçlerine yardımcı olmak için birçok otomatik lezyon segmentasyon tekniği ve bazı ikincil yardımcı araçlar önerilmiştir. MR görüntüleri üzerindeki analizlerde hekimlere yardımcı olması için görüntü ön işlemleri yapan yöntemler (Loizou vd., 2009: 4; Shiee vd., 2008: 8), görüntü işleme teknikleri ile yapay zekâ sistemlerini birleştiren yarı otomatik yöntemler (Admasu vd., 2003: 1083; Burget vd., 2011:

179; Van Leemput vd., 2001: 687) ve derin öğrenme modelleri ile otomatik lezyon tespit yapan yöntemlerin önerildiği görülmektedir (Brosch vd., 2016: 1229; Krizhevsky vd., 2012: 1; Subbanna vd., 2009: 2; Yıldırım & Dandıl, 2020: 13). Ayrıca, nitel ölçütlerle daha hızlı kararlar alınabilmesini sağlamada, MR görüntüleri üzerinde MS lezyonlarının otomatik tespiti için daha önce önerilen birçok karar destek sistemi (KDS) de bulunmaktadır (Daumer vd., 2007: 2; Esposito & De Pietro, 2011; Ghribi vd., 2019: 274; Santiago Rodrigo vd., 2019: 3). Özellikle son yıllarda, bilgisayar destekli KDS'lerin radyoloji alanında kullanımı hızla artmıştır ve tıbbi görüntülerin işlenmesinde rutin klinik uygulamaların bir parçası haline gelmiştir (Y. J. Kim vd., 2020: 62). Ek olarak, bazı çalışmalarda beyin sinyallerinin kullanılması ile MS teşhisi konusunda hekimlere yardımcı olan bilgisayar destekli melez KDS'ler de tasarlanmıştır (Ahmadi vd., 2019: 9). Dahası, teknolojinin gelişimi ile bilgisayar destekli KDS'lerin web ortamına taşınması ile daha kolay, esnek ve pratik kullanım imkânı sağlanmıştır. Web tabanlı tıbbi tanı uygulamaları karmaşık kurulum gerektirmediği, pahalı cihazlara ihtiyaç duymadığı ve hekimlerin tanı araçlarına kolay bir şekilde erişmesini sağladığı için öne çıkmıştır (H. Kim vd., 2020: 194; Veloso, 2014: 576). Ayrıca MS hastaların tedavi süreçlerinde günlük yaşamlarını düzenlemek için egzersiz planlaması, öz yönetim işlevlerinin takipleri gibi süreçlerde de web tabanlı KDS'lerin tercih edildiği görülmektedir (Miller vd., 2011: 5; Paul vd., 2014: 924).

MS lezyonlarının tespiti ve tedavi süreciyle ilgili uzun yıllardır birçok çalışma yapılmış olsa da hala aşılamayan bir takım teknik/teknolojik zorluklar ve sınırlılıklar bulunmaktadır (Zeng vd., 2020: 56). MS lezyonlarının bölütlemesi; lezyonun yoğunluğu, konumu, şekli ve boyutundaki büyük farklar, analizlerde çok merkezli kaynaklardan farklı tarayıcılar tarafından sağlanan MR görüntüleri büyük farklılıklar nedeniyle son derece zor bir süreçtir (Shanmuganathan vd., 2020: 338). Uzmanlar (genellikle hekimler ve radyologlar) ve otomatik lezyon bölütleme yaklaşımları arasındaki değerlendirme farklılıkları son yıllarda azalmış olsa da, uzmanların yaptığı bölütleme, otomatik yöntemlere göre çoğu durumda daha iyi performans göstermektedir (Lladó vd., 2012: 166) Bu nedenle, otomatik bölütleme yaklaşımlarının doğruluğunu artırmak için pek çok çalışma önerilmiştir ve daha yeni yöntemler bahsedilen zorluklarla başa çıkmak için önerilmektedir. Bu zorluklar ve kısıtlar, bu alanın araştırmalara açık olmasının ana nedenini oluşturmaktadır ve önceki çalışmaları geliştirmek veya yeni otomatik yöntemler geliştirmek isteyen araştırmacılar için motivasyon taşımaktadır (Danelakis vd., 2018: 84).

MS lezyonlarının el yordamına olanak sağlayan yardımcı araçları kullanılarak bölütlemesi zaman alıcı, sıkıcı, öznellikten uzak ve insan hatalarına açık bir süreçtir (Danelakis vd., 2018: 84). Ayrıca, MS lezyonlarının MR görüntüleri üzerinden hekimler tarafından incelendiği prosedürde, beyin taramaları tipik bir şekilde hacimsel olarak fazla olduğu için, gerçek zamanlı incelemelerde doğruluğu azaltabilmektedir (Filippi vd., 1998: 239). Ayrıca MR görüntülerinin değerlendirilmesi aşamasında, hatalar yapılması tanı sürecinde telafisi zor sorunlar oluşturabilmektedir (Rolak & Fleming, 2007: 58). Bundan dolayı, klinik uygulamalar için otomatik tespit yapan bir yöntem lezyon hacimlerini ölçmeyi mümkün kılabilir ve MR taramasını daha da standartlaştırılarak nicelleştirebilir (Jain vd., 2015: 368) Bu yöntemler aynı zamanda hedeflenen MR görüntüleri içindeki büyük miktardaki bilginin verimli bir şekilde işlenmesini sağlayan otomatik bir segmentasyon tekniğini de barındırabilir (Danelakis vd., 2018: 84). Bu nedenle, insan etkileşimini azaltmak, ortaya çıkan değerlendirici kaynaklı değişkenliğini/hataları azaltmak ve MR görüntülerinin bölütlemesini sağlamak için otomatik yöntemlerin geliştirilmesi ve bilgisayar destekli KDS'lerin önerilmesinin gerekliliği de açıktır (García-Lorenzo vd., 2013: 4). MS lezyonlarının tespiti ve değişimin takibi konusunda daha önce önerilen çalışmalarda, otomatik tespit sistemlerinin aşağıda listelenen çeşitli sınırlılıklara sahip olduğu ve tespit sistemlerinin başarımlarının belirlenmesi için kesin bir ölçüt olmadığı ve çalışmalarda farklılıklar içerdiği görülmüştür. Bunun en önemli nedeni sistemlerin sadece özgün bir verisetinde veya birbirinden farklı özelliklere sahip verisetleri üzerinde incelenmiş olması olarak yorumlanabilir (Lladó vd., 2012: 166).

MS hastalığının teşhis ve takibinde MR görüntüleri üzerinde yapılan önceki çalışmalar incelendiğinde:

- Verisetlerinin sınırlılıkları (farklı boyut, cihaz, tarama parametreleri içermesi gibi), MS lezyon tespitlerinde yüksek doğruluğa erişilmesi yönünde önemli bir engel oluşturabilmektedir.
- MS lezyonlarının otomatik tespitine imkân sağlayan derin öğrenme temelli bir altyapı ile hekimler için zorlu, uzun zaman alan bu süreç, daha kesin ve hızlı hale getirilebilir.
- Otomatik tespit yaklaşımları sayesinde insan kaynaklı hataların azalması mümkün olabilir ve bu nedenle hastaların yaşayacağı sıkıntılar azaltılabilir.
- Derin öğrenme modeline dayalı altyapıya sahip bir web tabanlı KDS ile ortam ve cihaz bağımlılığı olmadan MR görüntülerinde analizlerin yapılabilir ve süreçler kısalarak kolaylaşabilir.

## 1.1. Tezin Amacı

Bu Doktora Tezi çalışması “*MS lezyonlarının tespiti ve deęişiminin takibi için güçlü bir derin öğrenme modeli geliştirilebilir mi?*”; araştırma sorusuyla ortaya çıkmıştır. Bu sayede MS lezyonlarının tespitinin ve takibinin derin öğrenme modelleri kullanılarak daha hızlı, yüksek doğruluk oranı ve daha az işlem yükü ile gerçekleştirilebileceęi hipotezi kurulmuştur. “*Geliştirilen derin öğrenme modeli ile MS lezyonlarının tespiti ve deęişiminin takibinde bilgisayar destekli zeki bir karar destek sistemi önerilmeli*” önermesi de tez kapsamında üzerinde durulan bir dięer yaklaşım olmuştur. Ayrıca, tez çalışması kapsamında geliştirilen karar destek sistemi ile hekimlerin önerilen derin öğrenme modelini işlevsel olarak kullanmaları da öngörülmüştür.

Bu Doktora Tezi kapsamında yürütölen çalışmalar ile MS lezyonlarının tespiti için mevcut derin öğrenme mimarilerinin başarımlarının karşılaştırılması, elde edilen sonuçlardan yola çıkarak iyileştirilmiş bir derin öğrenme modelinin ortaya konulması, lezyonlardaki deęişimin takibi için derin öğrenme altyapısı ile desteklenmiş web tabanlı bir karar destek sisteminin tasarlanması amaçlanmıştır. Buna ek olarak, geliştirilen güncel modelin MS lezyonlarının tespiti ve takibi için hekimlerin kullanımına imkân sağlayacak bir araç olarak ortaya konması hedeflenmiştir. Ayrıca daha önce önerilen çalışmalar üzerinde yapılan literatür incelemesinde fark edilen bir ihtiyaç olduęu için, tez kapsamında MS hastalarına ait MR taramalarından toplanan kapsamlı bir verisetinin de bilim dünyasına kazandırılması planlanmıştır.

## 1.2. Tezin Organizasyonu

Bu tez çalışması şu şekilde organize edilmiştir:

Birinci bölümde MS hastalığının tanı ve tedavi süreci, bu süreçte MR görüntülemenin önemi, hekimlerin MR görüntüleri üzerinde çalışırken karşılaştığı zorluklar hakkında temel bilgiler ortaya konulmuştur. Tezin hipotezine ve amacına yönelik önceki akademik çalışmalar hakkında bilgiler verilmiş ve tez çalışmasının fikri temelleri sunulmuştur. Tez çalışmasının temel hipotezi, amacı ve tezin organizasyonu açıklanmıştır.

Tezin ikinci bölümünde çalışmaya konu olan derin öğrenme ve web tabanlı karar destek sistemleri ile ilgili literatür incelemesi yapılmıştır. Literatür incelemesinde öne çıkan çalışmalar ve tez kapsamında kullanılan açık verisetlerini konu edinen çalışmaların detayları, sonuçları ve sınırlılıkları incelenmiştir.

Üçüncü bölümde MS hastalığının detayları incelenmiştir. MS hastalığının tanımı, nedenleri, türleri ve teşhis süreci detaylı olarak sunulmuştur. Ayrıca, MS hastalığının teşhis ve sınıflandırılmasında kullanılan kriterler ve MS lezyonlarının incelenmesi için yararlanılan MR görüntüleme teknikleri incelenmiştir.

Dördüncü bölümde çalışma kapsamında kullanılan verisetleri, derin öğrenme mimarilerinin altyapıları, lezyon tespiti için önerilen modelin detayları ve yürütülen deneysel analizlerin sonuçları sunulmuştur. Tez kapsamında önerilen iMask R-CNN modelinin geliştirilmesi sürecinde deneyimlenen tüm yapıların örnekleri ve sonuçları yine bu bölümde detaylandırılmıştır.

Beşinci bölümde tez çalışması kapsamında önerilen DeepMSWeb isimli web tabanlı derin öğrenme sisteminin altyapısında kullanılan araçlar ve değişimin takibi için geliştirilen değişim tespit algoritması ve web tabanlı derin öğrenme sistemi incelenmiştir. Bu bölümde DeepMSWeb geliştirme ortamı ve elde edilen sonuçlar örnekleri ile sunulmuştur.

Tez kapsamında elde edilen verilerin detaylarıyla yorumlandığı tartışma kısımları altıncı bölümde yer almaktadır ve bu bölümde tez çalışmasının sınırlıkları hakkında da bilgi sunulmuştur.

Son olarak, tez çalışmasının sonuçları yedinci bölümde ana hatları ile sunulularak tez sonlandırılmıştır.



hücrelerin büyüklüğü anahtar kelimenin makalenin özet bölümünde ve başlık bölümünde kullanım sıklığı ile ilişkilidir. Buradaki bibliyografik analiz için VOSviewer uygulaması kullanılmıştır (Van Eck & Waltman, 2013: 3). Analiz sonucunda elde edilen grafikte *multiple sclerosis* anahtar kelimesi ile *mri*, *segmentation* ve *deep learning* kelimeleri arasındaki bağlantı şekillerdeki boyutlar büyüklüğü göze çarpmaktadır. Ayrıca görseldeki renk farklılıklarından çalışma alanlarının başka bilim dallarına ayrıldığı da görülmektedir.

Uzun yıllardır, MR görüntülerini kullanarak MS'in tespiti ve periyodik takibi için çeşitli çalışmalar yapılmaktadır (Bakshi, 2003: 219; Calabresi, 2004: 1935; Miller vd., 2008: 1157). Özellikle bilgisayar destekli otomatik tespit sistemlerinin kullanımı ile MS tanısında kayda değer ilerlemeler yaşanmıştır (Solari vd., 2004: 99; Yamamoto vd., 2010: 404). Bunların yanında MR görüntüleme teknolojileri bu kadar gelişmeden önce, klinik alanda da hekimler tarafından önemli çalışmalar yapılmıştır (McDonald vd., 2001: 121; Miller vd., 2005: 281; Poser vd., 1983: 227). Aynı zamanda, makine öğrenmesi algoritmaları ile MR görüntülerinde MS lezyonları olup olmadığını tespit eden birtakım çalışmalar da önerilmiştir (Ghahazi vd., 2014: 1). Bu ve benzeri çalışmalar belli oranda başarıya ulaşmış olsalar da hekimler tarafından uygulanacak şekilde bir ön işlem gerektirmeleri, veriseti boyutunun azlığı ve küçük MS lezyonlarının tespitindeki zorluklar nedeniyle tespit başarımının (doğruluğunun) düşük olduğu görülmektedir.

Temel görüntü işleme tekniklerini veya görüntü ön-işlemlerini kullanarak MS lezyonlarının tespiti için önerilen çalışmalara literatürde sıkça rastlanmaktadır. Bosc vd. (2003) bu çalışmalardan birinde sağlıklı görüntüleri de kullanarak, MS lezyonlarının periyodik takiplerdeki değişimi ve otomatik tespitine yönelik bir çalışma yapmışlardır. Çalışmada hazırlanan çatı uygulama ile MR görüntüleri üzerinden önce beyin bölgesini ayırmışlardır. Ayrılan görüntü üzerinde normalizasyon işlemi yapılmış, ardından beyin bölgesi görüntüsünden alçak geçiren filtre ile piksel bazında düzenleme önerilmiştir. Son adımda ise beyin bölgesindeki sağlıklı görüntülerden değişimler tespit edilmiştir. Sonuç olarak, MS tespiti için uzman görüşü ile benzer sonuçlara ulaşan ve bir çatı uygulama geliştirmişlerdir (Bosc vd., 2003: 645). Bir diğer çalışmada, Souplet vd. (2008) MS tespiti için temel görüntü işleme tekniklerini kullanmışlardır. Üç farklı MR sekansı üzerinde normalizasyon ve bölgeye odaklanma yaparak beyin bölgesini tespit etmişlerdir. T1w ve T2w sekansları üzerinde, geliştirilen bir algoritma aracılığıyla maksimizasyon işlemi yaparak MS şüphesi olan bölgeleri öne çıkarmışlardır. Son olarak şüpheli bölgelerin FLAIR sekanslarındaki görüntülerinde sınıflandırılması sağlanmıştır (Souplet vd., 2008: 2). MS lezyonlarının tespiti için Roura vd.

(2015) de, bir araç geliştirmişlerdir ve farklı tarayıcılardan alınan hasta verileri üzerinde test işlemleri yürütmüşlerdir. Sonraki aşamada, geliştirilen araç ile önce beyinde beyaz maddenin, ardından bu bölgedeki lezyonların tespitini başarmışlardır (Roura vd., 2015: 1033).

Görüntü işleme tekniklerini kullanarak MS lezyonlarının tespiti için daha önce önerilen sistemlerde genellikle MR kesitleri üzerinde normalizasyon yapılarak beyin bölgesinin öne çıkarıldığı ve lezyon alanlarının belirlendiği görülmektedir. Bu konuda incelenen çalışmaların özellikleri, kullandıkları metodoloji ve değerlendirmeleri Tablo 2.1’de sunulmuştur.

**Tablo 2.1.** Literatürde MS Tespiti İçin Temel Görüntü İşleme Algoritmalarını Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri

Referans ve Yıl	Veriseti	Hasta Sayısı	MR sekansları	Metodoloji	Değerlendirme ve Sınırlılıklar
(Bosc vd., 2003: 645)	Özgün Veriseti	8	T1w, FLAIR	Doğrusal olmayan yoğunluk normalleştirme yöntemi kullanılarak otomatik değişiklik algılama	Çalışmanın sonuçları genel ölçütlerle ölçülmemiştir. Yeterli miktarda veriseti ile test edilmemiştir.
(Souplet vd., 2008: 2)	MICCAI 2008	20	T1w, T2w, FLAIR	MS lezyonlarına görüntü ön işleme, morfolojik işlemler ve beklenti ve maksimizasyon algoritmasına dayalı otomatik segmentasyon	Yüksek performans elde edilememiştir.
(Roura vd., 2015: 1033)	MICCAI 2008, Özgün Veriseti (2)	70 + 45 +14	T1w, T2w, FLAIR	Görüntü işleme tekniklerine dayalı otomatik bir araç kutusu aracılığıyla MS lezyonu bölütlemesi	Ön işlem gerektirmektedir.

MS lezyon tespiti için görüntü işleme teknikleri ile çeşitli yapay zekâ yöntemlerini birleştiren çalışmalar da bulunmaktadır. Geremia vd (2010) yaptıkları çalışmada 3 farklı MR kesitinin üzerinde uzamsal rastgele karar ağacı algoritmasını kullanarak oluşturulan bir sınıflandırıcı ile lezyon alanlarını ortaya çıkarmışlardır. Çalışmada veriseti sınırlı olduğu, tespit başarımının düşük olduğu ve lezyon yoğunluğuna göre tespit başarımının değiştiği görülmüştür (Geremia vd., 2010: 117). Schmidt vd. (2012) T2w ve FLAIR sekanslı MR görüntülerini bir arada kullanarak MS hastalığında beyaz madde lezyonlarını otomatik tespit eden bir algoritma geliştirmişlerdir. Çalışmada, 3 Tesla (T) tarayıcıdan alınan farklı lezyon hacimlerine sahip ve MS lezyonu olan hastaların verilerinin matematiksel yöntemlerle değerlendirilmesi gerçekleştirilmiş ve elde edilen sonuçlar el yordamı ile belirlenen lezyonlarla iyi bir uyum sağlamıştır (Schmidt vd., 2012: 3782). Zhang vd. (2016) ise çalışmalarında, en yakın komşu algoritması ( $k$ -NN), destek vektör makineleri (DVM) ve karar ağacı algoritmalarını kullanarak

geliştirdikleri yapay zeka modeli ile açık bir veriseti üzerinde MS lezyonlarının tespitini önermişlerdir. MS kesitleri üzerinde lezyon alanlarını belirleme işlemi çok başarılı olmamasına karşın, beyin alanlarında MS lezyonu şüphesi olan bölgeler öne çıkarılmıştır (Zhang vd., 2016: 868). Bir başka çalışmada ise, Wu ve Lopez (2017) ise Haar dalgacık dönüşümleri, temel bileşen analizi (Principal Component Analysis, PCA) ve lojistik regresyon kullanarak MS kesitlerinde lezyon tespiti yapmışlardır (Wu & Lopez, 2017: 52). Knight ve Khademi (2016) ise bir başka çalışmada, sadece FLAIR kesitlerini kullanarak lezyon tespiti yapan bir bulanık sınıflandırma modeli önermişlerdir. Model yapay zekâ tekniklerinin yanında görüntü üzerinde ön işlem özelliklerini de içermektedir. Ancak önerilen modelin başarı oranlarının yetersiz kaldığı görülmüştür (Knight & Khademi, 2016: 23).

MS lezyonlarının tespiti ve takibi için çeşitli yapay zekâ algoritmalarını kullanarak önerilen sistemlerde, genellikle MR kesitleri üzerinde geleneksel yapılar ile deneysel çalışmalar yürütülmüştür. Bu çalışmalarda, genellikle çok yüksek lezyon tespit doğruluğuna ulaşamadığı ve lezyon alanlarının örtüşmesinin hassas olmadığı görülmüştür. Bu konuda incelenen ve daha fazla çalışmanın özellikleri, kullandıkları metodoloji ve değerlendirmeleri Tablo 2.2’de verilmiştir.

Son yıllarda, birçok alanda olduğu gibi, MS lezyonlarının tespitinde ve takibinde de derin öğrenme modellerinin de öne çıkmaya başladığı görülmektedir (Brosch vd., 2015: 1; Ravnik vd., 2018: 5; Valverde vd., 2017: 159). Bu çalışmaların birinde, standart Evrişimsel Sinir Ağı (ESA) kullanarak MS lezyonu tespiti için bir model önerilmiştir ancak çok yüksek doğruluk elde edilememiştir (Cerasa vd., 2012: 198). Maleki vd. (2012) kendi verisetleri üzerinde yaptıkları bir diğer çalışmada, MS tipinin tespiti için CNN’nin sınıflandırma aşamasında geliştirme yaptıkları modeli önermişlerdir. Bu model MS tiplerine göre MR kesitleri üzerinde bir sınıflandırma sistemi sunmaktadır (Maleki vd., 2012: 53). Bir başka çalışmada ise Atlason vd. (2019) CNN modeli ve otomatik kodlayıcı ile MS lezyon tespitini iki farklı veriseti üzerinde uygulamışlardır. Yürütülen deneysel çalışmalarda, MR kesitleri üzerindeki lezyonların büyük bölümünün tespit edilemediği görülmüştür (Atlason vd., 2019: 9). MS hastalığının derin öğrenme yöntemleri kullanılarak tespiti için önerilen bazı çalışmalarda standart bir ağ modeli kullanıldığı, dolayısıyla bu çalışmaların genelinde yüksek doğruluklar elde edilemediği görülmüştür. MS lezyonlarının tespiti için derin öğrenme temelli olarak önerilen birtakım çalışmaların genel değerlendirmesi Tablo 2.3’te özet olarak sunulmuştur.

**Tablo 2.2.** Literatürde MS Tespiti İçin Yapay Zekâ Algoritmalarını Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri

Referans ve Yıl	Veriseti	Hasta Sayısı	MR sekansları	Metodoloji	Değerlendirme ve Sınırlılıklar
(Geremia vd., 2010: 117)	MICCAI 2008	20	T1w, T2w, FLAIR	Uzamsal Rastgele Karar Ağacı	Kısıtlı bir veriseti kullanılmıştır. Lezyon yoğunluğuna göre başarımlar değişmektedir.
(Schmidt vd., 2012: 3782)	Özgün Veriseti	70	FLAIR, 3B T1w	Geliştirilmiş bir segmentasyon algoritmasını kullanarak MS lezyonu tespiti için otomatik bir araç	Yüksek performans elde edilemedi ve farklı veri setlerinde uygulanmamıştır.
(Zhang vd., 2016: 868)	eHealth	38	T2w	$k$ -NN, karar ağacı, DVM ve karşılaştırma sonuçları gibi makine öğrenme yöntemlerini kullanarak MS lezyon tespiti	Yüksek doğruluk performansı elde edilememiştir ve farklı veri setlerinde uygulanmamıştır.
(Wu & Lopez, 2017: 52)	Özgün Veriseti	67	-	Haar dalgacık dönüşümü, temel bileşen analizi ve lojistik regresyon kullanarak MS kesitlerinin tanımlaması.	Veriseti yetersizdir. Ölçümler anlamsız ve MS lezyonları tespiti örneklendirilmemiştir.
(Knight & Khademi, 2016: 23)	MICCAI 2016	10	FLAIR	Bulanık üyelik fonksiyonları ile kenar tabanlı hacim ortalaması modeli	Lezyon tespit performansının düşük olduğu görülmüştür.

Gelişmiş derin öğrenme modelleri kullanılarak önerilen bir çalışmada, Nair vd. (2020) 3B CNN kullanarak MS lezyonlarının tespiti için bir model geliştirmişlerdir. Çalışmalarında çıkarma katmanının lezyonların belirlenmesinde önemli olduğunu vurgulamışlardır. Ayrıca, küçük boyutlu lezyonların tespitinde yanlış tespit oranının yüksek olmasının, diğer boyutlardaki lezyonların tespitini olumlu etkilediğini öne sürmüşlerdir. Çalışmanın lezyon seçim sistemine genel bir öneri olarak sunulduğu görülmüştür (Nair vd., 2020: 9). Brosch vd. (2016) yaptıkları çalışmada, 3B evrişimsel çözücü ağları ile U-Net mimarilerini birleştirerek derin 3B CNN yapısını geliştirmişlerdir ve MS lezyonlarının tespiti için bir model önermişlerdir. Çalışmalarında, farklı lezyon boyutlarında belli bir başarımlar sağlamışlardır. Ancak, çalışmada kullanılan verisetinin boyutu düşük olup, büyük boyutlu bir veriseti üzerinde deneysel çalışmalar gerçekleştirilmemiştir (Brosch vd., 2016: 1235). Bir başka çalışmada ise, Gabr vd. (2020) MS lezyonlarının tespit için tam bağlantılı bir CNN derin öğrenme modeli

gelişmişlerdir. Özgün bir veriseti üzerinde yapılan deneysel çalışmalarda, belli oranda bir doğruluğa ulaşılsa da açık verisetleri üzerinde sistemin başarımı değerlendirilmemiştir (Gabr vd., 2020: 6). Bir başka çalışmada ise, Gessert vd. (2020) iki yollu CNN kullanılarak geliştirilen modelde özgün olarak hazırlanmış 3B veriseti üzerinde MS lezyonlarının tespitini gerçekleştirmişlerdir. Çalışmada kullanılan veriseti üzerindeki deneysel çalışmalarda, hekim (uzman) seçimlerine yakın sonuçlar elde edilmiştir. Çalışmanın sınırlılıkları olarak başarımın yüksek çözünürlüklü verisetlerinde de doğrulanmasının gerekli olduğu belirtilmiştir ve verisetinin hazırlanması ile kullanımının birtakım zorluklar içerdiği görülmüştür (Gessert, Krüger, vd., 2020: 7). Hilsdom vd. (2021) 2B CNN kullanarak geliştirdikleri bir araç ile büyük bölümü RRMS tipi MS hastalarından oluşan özgün verisetleri üzerinde MS tespitini sağlamışlardır. Çalışmanın model ve veriseti çeşitliliği konusunda geliştirilebilir olduğu ve lezyon tespit doğruluğu performansının artırılabilir olduğu değerlendirilmiştir (Hindsholm vd., 2021: 6).

**Tablo 2.3.** Literatürde MS Tespiti için Derin Öğrenme Modellerini Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri I

Referans ve Yıl	Veriseti	Hasta Sayısı	MR sekansları	Metodoloji	Değerlendirme ve Sınırlılıklar
(Maleki vd., 2012: 53)	Özgün Veriseti	150	-	MR görüntülerine göre MS sınıflandırması için CNN modeli	Değerlendirmeler yalnızca lezyon tespiti ile sınırlanmıştır.
(Cerasa vd., 2012: 198)	Özgün Veriseti	10	FLAIR	CNN modeli ile MS lezyon bölütlemesi	Veriseti sınırlıdır ve başarım düşüktür.
(Brosch vd., 2015: 3)	MICCAI 2008	500	T1w, T2w, FLAIR	Derin evrimsel kodlayıcı ağları kullanarak MS lezyonlarının bölütlemesi	Otomatik bölütleme performansı artırılabilir.
(Valverde vd., 2017)	MICCAI 2008	45	T1w, T2w, FLAIR	Kademeli 3B CNN ile otomatik MS lezyon bölütlemesi	Modelin yapısı geliştirilebilir.
(Ravnik vd., 2018: 5).	UMCL	60	T1w, T2w, FLAIR	CNN tabanlı farklı görüntü ön işleme ve büyütme yöntemleri ile lezyon bölütlemesi	Otomatik bölütleme performansı artırılabilir.
(Atlason vd., 2019: 9)	AGES-Reykjavik, MICCAI 2017	60 + 60	3B T1w, proton yoğunluklu (PD), 2B/3B FLAIR	Denetimli CNN otomatik kodlayıcı kullanarak lezyon bölütlemesi	Modelin yapısı geliştirilebilir.

MS lezyonlarının tespiti ve takibinde önerilen güncel bazı çalışmalar incelendiğinde, Birenbaum ve Greenspan (2017) geliştirdikleri çok katmanlı uzamsal CNN (Multi-View L-CNN) modelini kullanarak MS lezyonları tespitini yapmışlardır. Çalışmalarında verisetinin kısıtları nedeniyle kapsamının sınırlı kaldığı görülmektedir (Birenbaum & Greenspan, 2017: 117). Bir diğer çalışmada ise, Zhang vd. (2018) önerdikleri CNN modellerinde otomatik MS lezyon tespiti için bir çalışma gerçekleştirmişlerdir. Çalışmada verisetinde eğitim kümesinin büyüklüğünü arttırmak için veri artırımı teknikleri uygulanmıştır. Önerilen CNN’de parametrik rektifiye doğrusal ünite (PReLU) ve çıkarma tekniklerini eklenmiştir ve 10 kat (7 kat konvolüsyon katmanı ve 3 tam bağlantılı katman) derin sinir ağı ile bir model geliştirilmiştir. Çalışmalarında, sonuçların değerlendirmeleri sadece eğitim süreci üzerinden yapılmıştır (Zhang vd., 2018: 8). Wang vd. (2018) ise çalışmalarında toplu normalleştirme, çıkarma ve rastlantısal havuzlama teknikleri ile birleştirilen 14 katmanlı CNN modeli önermişlerdir. Çalışmada, her havuzlama bölgesinin aktivasyon çıkışlarından alınan çok terimli dağılımından örnekleme yoluyla elde edilen veriler stokastik havuzlama işlemine tabi tutulmuştur. Bu CNN modeli ile MS lezyonlarının tespiti belli bir doğrulukla başarılmasına rağmen önerilen sistemin sadece eğitim başarımı ölçülmüştür (Wang vd., 2018: 10).

Ravnik vd. (2018) çalışmalarında, CNN mimarisi kullanarak MS lezyonlarının otomatik tespiti için bir yöntem önermişlerdir. Çalışmada, MR görüntülerini histogram tabanlı standardizasyon, normalizasyon ve eksenlere göre döndürme işlemi gibi ön işlemlere tabi tutarak, sonrasında CNN ile eğitime süreci gerçekleştirilmiştir. Daha sonra çapraz doğrulama yaklaşımı kullanılarak aynı farklı veya araya eklenmiş tarayıcı veri kümelerinin görüntüleri üzerinden performans testleri yapılmıştır. Bunun yanında, çalışmada, önerilen sistemin performansı hekim başarımına yaklaşamamıştır (Ravnik vd., 2018: 5). Wang vd (2020) yaptıkları çalışmada uyarlanabilir seyrek Bayes modeline dayanan olasılıksal etiketleri birleştirerek MS lezyonları tespit eden derin öğrenme mimarisi geliştirmişlerdir. Ancak hekim seçimlerine göre başarımı düşük olan bir yöntem ortaya konulmuş ve veriseti sınırlı kalmıştır (Wang vd., 2020: 702). McKinley vd. (2020) ise çalışmalarında, taramalı derin öğrenme (DeepScan) modeli ile hacmi ve sayısı bakımından MS lezyonlarındaki değişimi inceleyen bir sistem geliştirmişlerdir (McKinley vd., 2020: 1). McKinley vd. (2021) çalışmalarında önerdikleri 3B CNN’den 2B CNN’e dönerek çalışan DeepScan modeli ile farklı verisetleri üzerinde eğitim ve testler gerçekleştirmişlerdir. Deneysel çalışmalarda, uzman görüşlerine yakın olarak bölütleme skorlarına ulaştıkları görülmüştür (McKinley vd., 2021: 8).

Bu tez konusu ile ilgili olarak Yıldırım ve Dandıl (2020) tarafından yürütülen bir çalışmada, maskeli bölgesel CNN (Mask R-CNN) üzerinde yapılan iyileştirme ile farklı boyutlardaki MS lezyonlarının seçimine özel bir model önerilmiştir. Önerilen model üzerinde iki farklı açık veriseti üzerinde eğitim ve test prosedürleri organize edilmiştir. Çalışmada, %84.90 DSC benzerlik oranına ulaşılan bir tespit başarımı sağlanmıştır. Çalışmada ayrıca, ResNet50 ve ResNet101 omurgaları üzerinde başarımların karşılaştırmaları yapılmıştır. Dahası, çalışma sonucunda önerilen model ile MS lezyonlarının tespiti için hekimlere yardımcı olacak ikincil bir araç sunulmuştur ve U-Net mimarisi ile elde edilen skorlar karşılaştırılmıştır (Yıldırım & Dandıl, 2020: 13). Yıldırım ve Dandıl (2021) tarafından yürütülen bir başka çalışmada iyileştirilmiş Mask R-CNN kullanılarak iki farklı veriseti farklı üzerinde deneysel çalışmalar gerçekleştirilmiştir. Bu çalışmada Detectron2 platformunda yapılan eğitim ve test süreçleri platform değişimi sonucunda başarımın yükseldiği gözlenmiştir. Ayrıca bu çalışmada farklı verisetlerinin eğitim süreçlerinde elde edilen en iyi ağırlıklar diğer verisetinde denenmiş ve etkili bir başarımların sergilediği görülmüştür (Yıldırım & Dandıl, 2021: 570).

MS lezyonlarının tespiti ve takibi için literatürde daha önce önerilen çalışmalar genel anlamıyla değerlendirildiğinde, bu çalışmalarda çoğunlukla boyutu küçük lezyon barındıran verisetlerinde yüksek başarımlar elde edilirken, boyutları orantısız lezyonları barındıran büyük verisetlerinde başarımın diğerlerine oranla daha da düşük olduğu görülmüştür. Ek olarak, bu çalışmalarda çoğunlukla farklı verisetleri ve karmaşık ağ model yapıları kullanıldığı tespit edilmiştir. Bunun yanında, çalışmalarda tutarsız ölçüm metrikleri kullanıldığı için başarımların birbiri ile karşılaştırılması kesin olarak mümkün olamamaktadır. Dolayısıyla, MS lezyonlarının derin öğrenme yöntemleri kullanılarak tespiti konusunda literatürde bulunan çalışmalarda, aynı verisetinin kullanılmaması, yöntemlerinin farklı olması ve benzerlik ölçütlerindeki farklılıklar gibi nedenlerle karşılaştırılmasının zor olduğu da açıktır. Ancak yine de son yıllarda MS lezyonlarının tespiti için önerilen derin öğrenme çalışmalarında önemli ilerlemeler olduğu görülmektedir. Tablo 2.4'te MS' in tespiti için derin öğrenme yaklaşımları kullanılarak önerilmiş bazı çalışmaların genel bir değerlendirmesi sunulmuştur.

**Tablo 2.4.** Literatürde MS Tespiti İçin Derin Öğrenme Modellerini Kullanarak Öne Çıkan Bazı Çalışmalar ve Değerlendirmeleri II

Referans ve Yıl	Veriseti	Hasta Sayısı	MR sekansları	Metodoloji	Değerlendirme ve Sınırlılıklar
(Brosch vd., 2016: 1235).	MICCAI 2008, ISBI 2015	43 + 21 + 377	T1w, T2w, FLAIR	Çok ölçekli özellik entegrasyonu için kısa yollara sahip derin 3B evrişimli kodlayıcı ağları aracılığıyla MS lezyonu bölütlemesi	Bölütleme doğruluk oranı diğer çalışmalara göre düşüktür ve başarımları artırılabilir.
(Zhang vd., 2018: 8)	eHealth, Özgün Veriseti	38 + 26	T2w	Parametrik ReLu aktivasyon fonksiyonu ve çıkartma işlemine dayalı gelişmiş bir CNN kullanarak MS lezyonu tanımlaması	DeneySEL çalışmalarda sunulan sonuçlar eğitim süreci ile sınırlı kalmıştır.
(Birenbaum & Greenspan, 2017: 117).	ISBI 2015	5	T1w, T2w, FLAIR	Çok katmanlı uzamsal CNN kullanarak MS lezyonu bölütlemesi	Veriseti sadece 5 hasta ile sınırlandırılmıştır.
(Wang vd., 2018: 10).	eHealth, Özgün Veriseti	38 + 26	T2w	Toplu normalleştirme, çıkarma ve rastlantısal havuzlama ile 14 katmanlı CNN kullanarak MS lezyonlarının tanımlanması	Çalışmanın sonuçları metrikler ile ölçülmemiş ve karşılaştırılmamıştır.
(Valcarcel vd., 2018: 389)	Özgün Veriseti	98	T1w, T2w, FLAIR	MS lezyonlarının bölütlemesi için otomatik yöntem	Bölütleme doğruluğunun artırılabilir olduğu görülmüştür.
(Zhao vd., 2018: 99)	MICCAI 2008	45	T1w, T2w, FLAIR	Level set (düzey ayarlama) yöntemi kullanarak MS lezyonu bölütlemesi	Sonuçlar başka verisetleri ile karşılaştırılabilir.
(Gabr vd., 2020: 6)	Özgün Veriseti	1008	3B T1w, T2w, PD, 2B FLAIR	Tam evrişimli sinir ağı kullanarak MS lezyonu bölütlemesi	Sonuçlar farklı yöntemlerle karşılaştırılabilir.
(Nair vd., 2020: 9)	Özgün Veriseti	1064	T1w, T2w, FLAIR, PD	CNN mimarisinin içindeki belirsizliği azaltma, filtreleme içeren bir model	Lezyon seçimleri kendi içinde karşılaştırılmıştır. Bölütleme doğruluğunun artırılabilir olduğu görülmüştür.
(Gessert, Krüger, vd., 2020: 7)	Özgün Veriseti	89+33	FLAIR	İki yollu CNN ile MS lezyonu segmentasyonu	Sonuçlar farklı yöntemlerle karşılaştırılabilir.
(Wang vd., 2020: 702)	MICCAI 2008	45	T1w, T2w, FLAIR	Olasılıklı etiket füzyonu ile birleştirilmiş uyarlanabilir seyrek Bayes modeli kullanarak beyin MRG'sinde MS lezyonu segmentasyonu	Bölütleme doğruluğunun artırılabilir olduğu görülmüştür.

**Tablo 2.4**'ün Devamı

Referans ve Yıl	Veriseti	Hasta Sayısı	MR sekansları	Metodoloji	Değerlendirme ve Sınırlılıklar
(McKinley vd., 2020)	Özgün Veriseti	32	FLAIR	3B CNN'den 2B CNN'e dönerek çalışan taramalı derin öğrenme modeli	Bölütleme performansının düşük kaldığı görülmüştür.
(McKinley vd., 2021: 8).	MSSEG, Özgün Veriseti	15+122	T1w, T2w, FLAIR	3B CNN'den 2B CNN'e dönerek çalışan taramalı derin öğrenme modeli	Yüksek çözünürlüğe sahip verisetlerine ihtiyaç duymaktadır.
(Hindsholm vd., 2021: 6)	Özgün Veriseti	53	FLAIR	2B CNN kullanan bir derin öğrenme aracı	Bölütleme doğruluğunun artırılabilir olduğu görülmüştür.
(Yıldırım & Dandıl, 2020: 13)	eHealth, UMCL	38+60	T2w, FLAIR	İyileştirilmiş Maskeli R-CNN	Bölütleme başarımı yüksek, hekimler için yardımcı bir araç önerilmiştir.
(Yıldırım & Dandıl, 2021: 570)	ISBI2015, MICCAI2008	5+45	FLAIR	İyileştirilmiş Maskeli R-CNN	Verisetlerinde çapraz doğrulama sonucunda önerilen modelin başarısı görülmüştür.

MS lezyonlarının tespiti ve takibi için bir karar destek sistemi (KDS) şeklinde önerilen çalışmalar da bulunmaktadır. Bu karar destek sistemleri mobil uyumlu, web-tabanlı, masaüstü uygulaması şeklinde veya bunların birleşimi ile melez bir yapılar da olabilmektedir. Web tabanlı tıbbi tanı uygulamaları, kurulum gerektirmediği, pahalı cihazlara ihtiyaç duymadığı, hekimlerin tanı araçlarına kolay bir şekilde erişmesini sağladığı için öne çıkmıştır (H. Kim vd., 2020: 1). MS lezyonlarının otomatik tespiti için önerilen zeki sistemlerin çoğunun bir KDS modeli ya da altyapı unsuru olarak tasarlandığı görülmektedir (Daumer vd., 2007: 5; Esposito & De Pietro, 2011: 1340; Veloso, 2014: 26).

Web tabanlı KDS şeklinde önerilen uygulamalar ile MS lezyonlarının izlenmesi, hastalığın ilerleme sürecindeki tahlil ve tetkiklerin takibi ve ilaç tedavilerinin etkilerinin izlenmesi için önerilen birçok akademik çalışma bulunmaktadır. Bu çalışmaların birinde, Daumer vd. (2007) yaptıkları çalışmada MS hastalarının tedavi süreçlerini ve hastalığın ilerleme durumunu takip etmek için web tabanlı bir KDS önermişlerdir (Daumer vd., 2007: 5). Bir diğer çalışmada ise, Ma vd. (2015)'de MR görüntülerini de kullanabilecek web tabanlı bir altyapı sistemi önermişlerdir. Önerilen sistem, MR görüntüleme cihazlarından alınan görüntüler üzerinden lezyon sayımı, lezyon alanlarının bölütlemesi gibi işlemlerinin yanında, yapılan tahlil ve tetkiklerin takibinin yapılabileceği bir altyapı sunmaktadır. (Ma vd., 2015: 259). Veloso vd. (2014)'de ise önerdikleri sistemde MS hastalığının semptomlarının, tetkiklerin sonuçlarını, engellilik durumlarını kayda geçirerek hastalığın ilerlemesini tahmin eden web tabanlı KDS önermişlerdir (Veloso, 2014: 26). Tallner vd. (2016) de, çalışmalarında hastaların fiziksel

aktivitelerini izlemek, gerektiğinde müdahale edebilmek için bir takip sistemi önermişlerdir (Tallner vd., 2016: 327). Başka bir çalışmada, Engelhard vd. (2017) ise, MS hastalığında kullanılan ilaçlar ve etkilerini takip için uzaktan erişimli bir uygulama geliştirmişlerdir (Engelhard vd., 2017: 30).

Özellikle son yıllarda derin öğrenme modelleri ve donanım yapılarındaki hızlı gelişmelerle orantılı olarak, derin öğrenmeye dayalı web tabanlı karar destek sistemlerinin de yaygınlaştığı görülmektedir. Örneğin, Mahmoudi vd. (2010) çalışmalarında, tıbbi görüntüler için web tabanlı işlem ve görselleştirme sağlayabilen bir yazılım geliştirmişlerdir. Geliştirilen uygulama kullanılarak ön işlemden geçirilen MR kesitleri üzerinde MS lezyonlarının tespiti ve görselleştirilmesi yapılmıştır. Zeki bir altyapı içermeyen çalışmada, sistemin bu bakımdan geliştirilebilir olduğu değerlendirilmiştir (Mahmoudi vd., 2010: 172). Jain vd. (2016) ise farklı sekanslardan alınan görüntüleri bir arada kullanarak sayısal modeller ile lezyon alanlarını belirlemek için bir KDS'ye altyapı olacak şekilde bir model geliştirmişlerdir (Jain vd., 2016: 2). Frisch vd. (2020) çalışmalarında, MS Atlas isimli web uygulaması ile genlerin MS üzerindeki etkisinin üç farklı yöntemle görselleştirilmesini sağlamışlardır (Frisch vd., 2020: 122).

Bu tez kapsamında da MS lezyonlarının tespiti ve değişiminin takibi için derin öğrenme modellerini kullanarak geliştirilen bir KDS önerilmiştir. Bu uygulamada lezyon alanlarının oransal değişimi sistem tarafından otomatik tespit edilmektedir. Önerilen sistem hastalığın takibinde hekimlere yardımcı olarak MS hastalığının tedavi sürecinde önemli katkı sağlayacağı açıkça görülmektedir (Yıldırım & Dandil, 2021: 1).

MS hastalığı konusunda KDS önerilerinin bulunduğu çalışmalar incelendiğinde genel olarak hastalığın ilerleme sürecinin takibinin konu alındığı görülmüştür. MR kesitleri üzerinde çalışan zeki KDS uygulamalarına pek rastlanmamıştır. Ancak MR kesitlerini, kan ve diğer tahlil unsurlarını bir arada takibine yönelik KDS önerileri bulunmaktadır. Önerilen KDS yapılarında zeki unsurlar bulunmadığı ve MR kesitlerinden lezyon tespiti konusunda otomatik KDS önerilerine çok fazla rastlanmamıştır. Tablo 2.5'te MS hastalığı alanında KDS olarak önerilen yapılardan literatürde öne çıkan bazı çalışmalar ve genel değerlendirmeleri sunulmuştur.

Tez kapsamında yapılan kapsamlı literatür incelemesi sonucunda, MS lezyonlarının otomatik tespiti ve değişiminin takibini yapabilen ve hekimlere destek olabilen bilgisayar destekli sistemlere ihtiyaç olduğu görülmüştür. Ayrıca, daha önce önerilen hali hazırdaki çalışmaların çoğunun başarımının, hekimler tarafından elle yapılan seçimlerin sonucuna göre

düşük kaldığı anlaşılmıştır. Bunun yanında, derin öğrenme tekniklerinin lezyon alanlarını belirlemede etkili bir yöntem olduğu ve yeni model önerilerinin geliştirilmesi ise hala ihtiyaç olduğu değerlendirilmiştir. Ayrıca daha önce önerilen modellerin büyük çoğunluğunun bir KDS uygulaması olarak sunulmadığı da görülmüştür. Dolayısıyla, MS lezyonlarını başarılı olarak tespit eden bir model üzerinde geliştirilecek KDS'lerin hem hekimlerin karar vermesinde yardımcı olacağı, hem de bazı prosedürleri kolaylaştıracağı kanısına varılmıştır.

**Tablo 2.5.** Literatürde Öne Çıkan MS Alanında Önerilen KDS Uygulamaları ile İlgili Bazı Çalışmalar ve Değerlendirmeleri

Referans ve Yıl	Amaç	Değerlendirme ve Sınırlılıklar
(Daumer vd., 2007: 5)	Hastalık sürecinin takibi	Sadece takip amaçlı bilgi toplanmaktadır.
(Ma vd., 2015: 259)	Hastalık sürecinin takibi	Sadece takip amaçlı bilgi toplanmaktadır.
(Engelhard vd., 2017: 30).	Hastaların ilaçlarının ve etkilerinin takibi	Sadece takip amaçlı bilgi toplanmaktadır.
(Mahmoudi vd., 2010: 172)	MR kesitleri ve diğer tetkikler için beraber değerlendirilmesi	Zeki sistemleri içermeyen bir çatı uygulamasıdır.
(Veloso, 2014: 26)	Semptonlar, tahliller ile engellilik bilgilerine ilerleme durumunu tespit etmek	MR kesitlerini kullanılmamıştır.
(Jain vd., 2016: 2)	Görüntü işleme teknikleri ile lezyon alanlarını belirleme	Sistem bir KDS altyapısı olarak önerilmiştir.
(Frisch vd., 2020: 122).	Gen temelli MS analizi gerçekleştirilmesi	MR kesitlerini kullanılmamıştır.
(Yıldırım & Dandil, 2021: 1)	Derin öğrenme modeli kullanan sistem ile MS lezyonlarının ve değişiminin takibi	Sistem başarıyla lezyon alanlarını ve değişimlerini belirlemektedir.

### 3. MULTİPL SKLEROZ

Multiple Skleroz (MS) beynin beyaz cevherinde ve omurilikte çeşitli büyüklüklerde lezyonlara yol açan, değişken ölçüde aksonal kayıp ile birlikte birincil sinir hasarı ile fark edilen, MSS'nin kronik bir hastalığı olarak tanımlanır. MS, genç erişkinlerde nörolojik sakatlığın önde gelen nedeni olan sinir hücrelerinin ilerleyici kaybı ile giden ve bu kayba bağlı olarak sinir sistemi fonksiyonlarının yitimine neden bir hastalıktır (Makhani & Tremlett, 2021: 1). MS en yaygın olarak, klinik seyrin göreceli durgunluk (remisyon) dönemleri ve ayrılan akut nörolojik semptomlar (nüksler) ile karakterize edildiği, tekrarlayan-düzelten bir formda ortaya çıkar(Cree vd., 2021: 378). MS hastalığı, ilk olarak 1868 yılında Jean-Martin Charcot tarafından tanımlanmıştır (Ünal vd., 2018: 1)

MS beyin ve omurilik bölümlerinden oluşan MSS'yi etkileyen en yaygın nörolojik hastalıktır. MS ölümcül olmayan, bulaşıcı ve kalıtsal olmayan beyin de oluşan bir nörolojik hastalıktır (Karabudak, 2014: 7). Ayrıca, MS kronik ve ciddi bir hastalık olmakla beraber çoğu hasta uzun ve kaliteli şekilde normal veya normale yakın bir yaşam süresine sahiptir. Hastaların büyük bir kısmı ciddi özürülük olmaksızın yaşamını devam ettirebilir (Ragonese vd., 2008: 126).

MS ilerleyici hastalıklarından biri olup beynin morfolojisini ve yapısını değiştirerek ilerler. Sinir sinyallerinin bir nörondan diğerine hızlı bir şekilde iletilmesinden sorumlu nöronal lifleri (akson) saran yağlı materyal olan miyelin kılıfının hasarından kaynaklanmaktadır (Zeng vd., 2020: 1). Miyelin kaybı (demyelinizasyon) bu aksonların sinir sistemi boyunca sinyal iletilmesini engeller ve böylece sinyallerin doğru iletilmesine dayanan vücut fonksiyonlarının bozulmasına neden olur (Mortazavi vd., 2012: 300). MS'te, etkilenen MSS alanına bağlı olarak bulanık görmeden, ağır kas güçsüzlüğü ve bozulmasına kadar birçok semptom gözlenmektedir (Brownlee vd., 2017: 389). Aksonal kayıplara ek olarak MS hastalığı beynin beyaz maddesinde çoklu iltihap odaklarına neden olabilmektedir. Aksonal kayıpların aksine fokal (odağa doğru) iltihaplar geri dönüşümlüdür; bu nedenle aksonal kayıplar hastalığın ilerlemesi için uygun belirteçler olarak kabul edilmektedir (Tedeschi vd., 2005: 280).

#### 3.1. MS'de Epidemiyoloji (Kimlerde Görülür ve Görülme Sıklığı)

MS genellikle gençlerde ortaya çıkmaktadır. Ortalama tanı yaşı otuzlu yaşlardır. Hastalık kadınlarda erkeklere oranla daha sık gözlenmektedir. MS ekvatorдан uzaklaştıkça artmakta ve beyaz ırkta daha sık ortaya çıkmaktadır (Karabudak, 2014: 7). MS görülme sıklığı

bölgeler arasında değişmekte olup, yüksek enlem bölgelerinde her 100.000'de 8 ila 10 yeni vaka görülmektedir (Montalban vd., 2018: 97).

Dünya çapında yapılan incelemelere göre 2020 yılında rahatsızlığı devam eden 2.8 milyon MS hastası olduğu görülmektedir. MS hastalığının görülme sıklığı her 100.000 kişide Avrupa'da 133, Amerika'da 112, Orta-Doğuda 30 iken Doğu Asya, Afrika ve Pasifik'te 5-9 arasında değişmektedir (Atlas, 2020: 21).

Türkiye'de yapılan MS tekrarlanma sıklığı (prevelans) çalışmaları sınırlı sayıda olup genellikle bölgesel olarak yapılmıştır. Yapılan bir çalışmada iki kırsal bölgede 10 yıllık periyotta takip ile elde edilen verilere göre; 100.000'de 47.9 hasta görülmüştür. Hastaların yaş aralığının 30-50 ve teşhis aralığının en çok 30-34 yaş arası olduğu görülmüştür. Cinsiyet açısından bakıldığında kadın hastalarının sayısı erkek hastalara göre 2.5 kat fazla olduğu görülmüştür (Bölük vd., 2021: 41). 2010 yılında ülkemizde yayınlanan bir başka çalışmada Edirne ilinde yapılan incelemede, MS prevelansının 100.000'de 36.5 olduğu görülmüştür (Çelik vd., 2011: 194). Bu bilgiler ışığında Türkiye genelmesi yapılacak olursa, MS'in ülkemizde de yaygın bir hastalık olduğu görülmektedir.

### **3.2. MS'de Etimoloji (Nedenleri ve Belirtileri)**

MS' in nedeni tam olarak bilinmese de otoimmün bir hastalıktır. Otoimmün hastalık, vücudun bağışıklık sistemi hücrelerinin kendi hücrelerine saldırması anlamına gelmektedir. Nedeni tam olarak bilinmemekle birlikte bazı enfeksiyon ve virüslerin hastalık gelişimine neden olabileceğine dair kanıtlar mevcuttur (Donati, 2020: 27; Marrodan vd., 2019: 891) MS'e genetik olmamakla birlikte bazı yatkınlık genlerinin mevcudiyeti de görülmektedir (Zahoor vd., 2021: 3182). Ayrıca, MS bulaşıcı bir hastalık değildir (Contrò vd., 2017: 54).

MS hastalarında MSS hasarına bağlı tüm belirti ve bulgular aynı anda ortaya çıkabilir ya da bazıları çok sık, bazıları da kırmızı bayrak kabul edilecek kadar seyrek olarak ortaya çıkarlar (Calabresi, 2004: 1935). Kol ve bacaklarda güçsüzlük, duysal belirtiler, yürüme ya da bir şeyler kaldırma gibi istemli şekilde yapılan hareketler esnasında ortaya çıkan kasın kontrol yahut koordine eksikliği, mesane problemleri, yorgunluk, çift görme, görme bulanıklığı gibi görsel belirtiler, konuşma bozukluğu, bellek-konsantrasyon-dikkat bozukluğu gibi kognitif süreçler sık görülen belirtilerdir (Brownlee vd., 2017: 389). Buna karşılık hareket bozuklukları, epileptik nöbet, baş ağrısı, demans düzeyinde bilişsel yıkım, işitme kaybı, kas kayıpları seyrek görülen belirti ve bulgulardır (Ünal vd., 2018: 9). MS hastalarında en sık görülen hastalık belirtileri ve bu belirtilerin oranları Tablo 3.1'de görülmektedir.

**Tablo 3.1.** MS Hastalığı Başlangıcındaki Belirtiler ve Görülme Sıklıkları

Belirtiler	Sıklıkları
Bir ya da daha fazla ekstremitede güçsüzlük	%35
Optik nörit	%20
Parestezi	%20
Diplopi	%10
Vertigo	%5
Mesane problemleri	%5
Diğer	<%5

**Kaynak:** (Ünal vd., 2018: 9)

MS hastalarının %10'unun 20 yıldan fazla bir süre iyi olabilmesine rağmen, %50'sinin maksimum 15 yıl sonra yürümek için yardıma ihtiyacı olmaktadır ve bazı durumlarda hastalar aylar içinde ölmektedir (Goldenberg, 2012: 175; Navikas & Link, 1996: 322). Hastalığın başlangıç yaşı ne kadar küçükse MS ilerleme durumu da o kadar fazla olabilir (Bethune vd., 2011: 69; Till vd., 2011: 1027). Bu hastalık Kuzey Amerika, Kuzey Avrupa ve Orta Doğu'da daha yaygındır. Yalnızca ABD'de 250.000 ila 350.000 MS hastası var. Hastalığın nedenleri tam olarak bilinmemekle birlikte, çevresel faktörler ve genetik etkiler hastalığın en muhtemel nedenleri olarak kabul edilmektedir (Compston & Coles, 2002: 1221; Patsopoulos, 2018: 1).

### 3.3. MS Tanısının Konulması

MS belirtileri birçok hastalıktaki belirtilere benzerdir. Bu nedenle MS tanısı uzman hekimlerce detaylı bir hastalık hikayesi, nörolojik muayene ile diğer hastalıkların dışlanması sonrasında konulabilir. Tanı koymak için bir nöroloji uzmanı sırasıyla;

- Belirtileri dikkatle sorgular,
- Yürüme, kas gücü, refleksler ve dokunma duyusu gibi fonksiyonları test eder,
- Görme keskinliğinde azalma, göz dibi patolojileri, anormal göz bebeği yanıtları ve göz hareketleri açısından değerlendirir,
- MS lezyonlarını araştırmak için beyin ve omurilik MR görüntülemelerini planlar,
- Anormal immün belirteçlerin değerlendirilmesi ve tanının kesinleştirilmesi için belsuyu incelemesi yapar,
- Diğer hastalıkları dışlamak amacıyla kan testleri yapar (Goldenberg, 2012: 175; Ünal vd., 2018: 9).

MS'in çeşitli türleri mevcuttur. Çoğu hastada başlangıç, ataklarla ilerleyen MS adı verilen ataklar halinde gelip düzelen belirtiler şeklindedir. Belirtiler saatler ve günler içinde ortaya çıkar ve birkaç gün ve bazen bir haftada düzelir. Bu ataklar düzensiz aralıklarla ortaya çıkar. Tekrarlayan ataklar bazı hastalarda özürllülüğe neden olabilir. Bazı hastalarda ise ataksız ilerleyebilir.

MS için tek başına yeterli bir tanı testi yoktur. Teşhis için;

(1) MSS'nin beyaz maddesindeki en az iki farklı lezyon (plak veya iz) incelemesi yapılır (alana yayılma kriteri),

(2) MS hastalığının iki farklı zaman diliminde belirtilerin görülmesi takip edilir (zamana yayılma kriteri),

(3) Beyin omurilik sıvısının analizinde MSS'de iltihap görülüp görülmediği araştırılır (iltihap kriteri)

Bu kriterlerden bir veya daha fazlasının varlığı hastalığın devamındaki seyrine göre genel bir MS tanısına izin verir. MS teşhisine ilişkin hekimler zamana yayılma kriterinin sağlanması için en az 3 ay veya daha önceki MR görüntüsü ile tespit edilmesinin gerektiğinde hem fikirdir. Ayrıca iltihap kriterinin ikincisi klinik ve para-klinik seviyelerde eksik olduğunda; alan yayma kriterinin yerini alabileceğini hekimler tarafından kabul edilmektedir (Goldenberg, 2012: 175; Thompson vd., 2018: 162)

MS hastalığının tanısının konulmasında başarıml için hekimler uzun yıllardır çalışmaktadır. McDonald Kriterleri olarak bilinen kesin teşhis için aranması gereken semptomlar ilk defa 2001 yılında kabul edilmiştir (McDonald vd., 2001: 121). Daha sonra bu kriterler sırasıyla 2005 (Polman vd., 2005: 840), 2010 (Polman vd., 2011: 292) ve 2017 yıllarında revize edilmiştir (Thompson vd., 2018: 162). Hastalara MS teşhisi koymak için doktorların takip ettiği McDonald Kriterlerinin 2017 yılındaki son güncellenen hali Tablo 3.2'de anlatılmıştır. Bu tabloda OKB, oligoklonal bantı ve BOS ise beyin omurilik sıvısını ifade etmektedir.

**Tablo 3.2.** Mcdonald Kriterleri 2017

Atak	Objektif Klinik Bulgulu Lezyon Sayısı (MRG)	MS Tanısı İçin Gerekli Ek Veri
≥2 atak	≥2	Yok
≥2 atak	1+ öyküde başka bir alanda ki lezyona ait atak	Yok
≥2 atak	1	MSS’de farklı bir alandaki lezyona ait yeni bir atak veya MRG ile mekânda yayılımın gösterilmesi
1 atak	≥2	Ek bir klinik atak veya MRG 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 ile mekânda yayılımın gösterilmesi ve ek bir klinik atak veya MRG ile zamanda yayılımın gösterilmesi veya BOS-spesifik OKB varlığı
Sinsi ilerleme	1 yıl klinik izleme (retrospektif veya prospektif, ataktan bağımsız olarak)	Aşağıdakilerin 2’si; <ul style="list-style-type: none"><li>• MS tipik alanlarda ≥1 lezyon</li><li>• Spinal kord da ≥2 lezyon</li><li>• BOS-spesifik OKB varlığı</li></ul>

BOS: Beyin Omurilik Sıvısı,  
OKB: Oligoklonal bantlar (immünoglobulin bantlar)

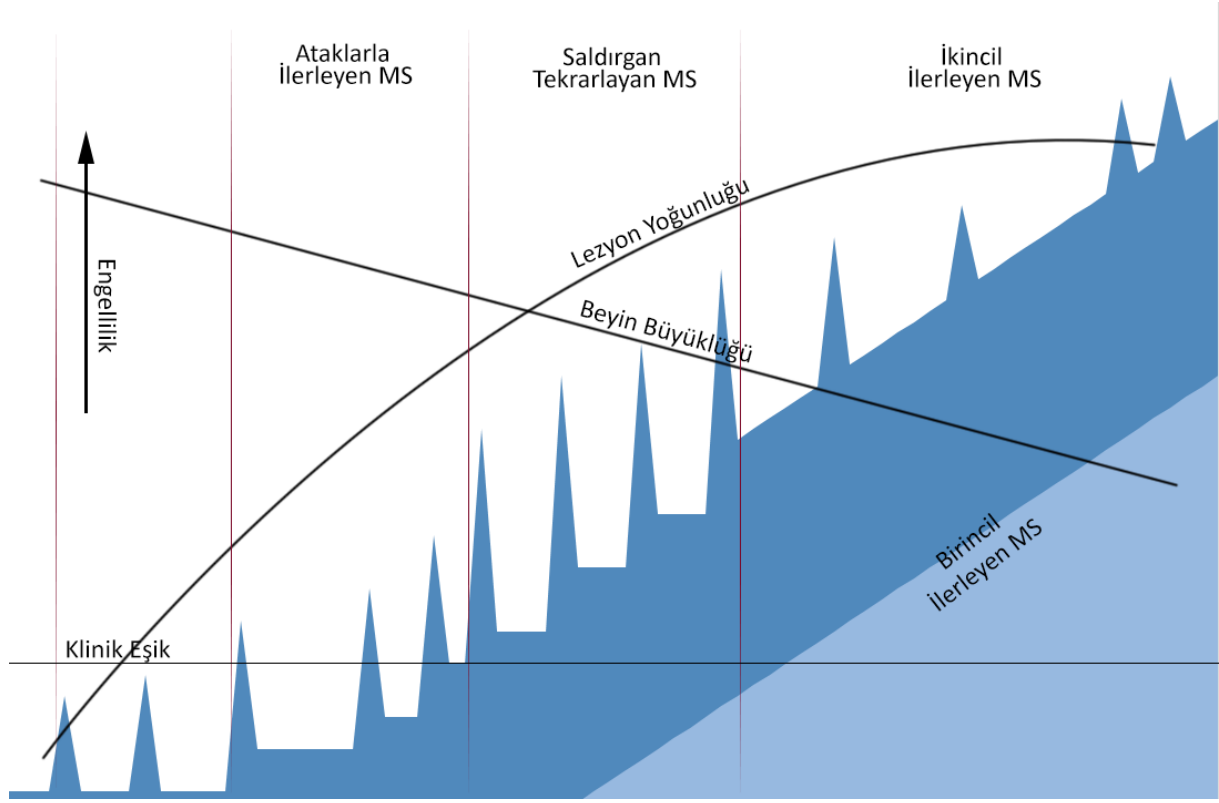
**Kaynak:** (Thompson vd., 2018: 162)

### 3.4. MS Türleri

MS hastaları dört klinik grupta kategorize edilmektedir. MS kategorileri; ataklarla seyreden MS (RRMS, Relapsing–Remitting MS), ikincil ilerleyici MS (SPMS, Secondary Progressive MS), birincil ilerleyici MS (PPMS, Primary Progressive MS) ve saldırgan tekrarlayan MS (PRMS, Progressive Relapsing MS). MS kategorileri atakların aralıkları ve şiddetleri ile belirlenmektedir. Şekil 3.1’de MS tiplerinin geçişleri, ilişkileri, ataklarla ilişkisi, aralarındaki geçişleri ve hastalığın engellilik seyrine etkisi görülmektedir. Şekilde tepeler halinde ataklar, mavi bölge lezyon alanının hacimsel değişimini temsil etmektedir. Lezyon alanlarının artışı ile beyin bölgesinin hacmi azalmakta ve engellilik oranının arttığı açıkça görülmektedir.

Hastalığın seyri genellikle ataklarla ve klinik izole sendrom (KİS, Clinically Isolated Syndrome, CIS) adlı nörolojik semptomlar ile başlar. KİS semptomlar ve klinik incelemeler uzman hekim tarafından araştırıldıktan sonra MS ilerleme ve oluşum seyrine göre teşhis belirlenir. Hastaların çoğunda semptomlar ve belirtiler (ataklar veya relapslar) ile karakterize edilir, ardından tam veya kısmi iyileşme olan ve relapslar arasında hastalık ilerlemesi olmayan

ataklarla seyreden MS fenotipi (RRMS) ile başlar (Inojosa vd., 2021). Sıklıkla, bu tekrarlayan-düzelten seyri ataklardan bağımsız olarak nörolojik fonksiyonun sinsi şekilde kötüleştiği ikincil ilerleyici MS olarak adlandırılan (SPMS) evresi izler (Cree vd., 2021: 379; Lassmann vd., 2012: 648).



**Şekil 3.1.** MS Tiplerinin Geçişleri ve İlişkileri Grafiği

Ataklarla seyreden MS (RRMS, Relapsing Remitting MS), MS hastalarının yaklaşık %85'ini etkileyen en yaygın formudur. Bu kategorideki MS hastalarında belirtilerin stabil olması veya ortadan kalkması durumunda semptomların yeniden nüks etmesi ve ardından hafifleme dönemi ile kendini göstermektedir. Bu nüks etmeler; birkaç hafta veya ay içinde kısmi veya tamamen hastalığın iyileşmesi izlenmektedir (Oh vd., 2018: 758).

İkincil ilerleyici MS (SPMS, Secondary Progressive MS) kategorisindeki hastalarda stabil olan ve tekrar nüks sıklıkla meydana geldikten sonra hastalığın tekrarlayan ilerleyici evresi başlamaktadır. SPMS hastaları, RRMS hastalarından sakatlık dereceleri ve takip eden yeniden nüks etme sonra temel düzelme eksikliği bakımından farklılık göstermektedir. Çok sayıda RRMS hastası ilerleyen süreçte SPMS'nin seyrine girer (Cree vd., 2021: 379).

Birincil ilerleyici MS (PPMS, Primary Progressive MS); hastaların yaklaşık %10'unu etkiler. Belirtiler baştan itibaren giderek kötüleşmeye devam eder. Birincil ilerleyici MS'de

(PPMS), önceki relapslar olmaksızın fiziksel yeteneklerde bir düşüş meydana gelir (Kantarci vd., 2016: 289; Ransohoff vd., 2015: 135). Bu MS formu, hastalığın tedavisinde kullanılan ilaçlara karşı daha dirençlidir.


Saldırgan tekrarlayan MS (PRMS, Progressive Relapsing MS); hastalığın nadir bir formudur ve hastaların %5'inden daha azını etkiler. PRMS'de hastalık süreci boyunca devamlı kötüleşen semptomlarla ve bazı zamanlarda hızla kötüleşerek seyredir. Bu kategorideki hastalarda süreç boyunca hafifleme görülmemektedir (Goldenberg, 2012: 175; Nusbaum vd., 2000: 1421).

### **3.5. MR Görüntüleme ile MS Teşhisi**

MR Görüntüleri (MRG) MS'in tanısını ve takibini değerlendirmede ve MS ile ilişkili durumlarda öncelikli olarak kullanılmaktadır. MRG, lezyonları saptamada hassas bir tetkiktir ama kesin tanı koyulmasında bazı kriterlerin kullanılması gerekliliği ortaya çıkmıştır. Günümüzde en yaygın olarak kullanılan McDonald Kriterlerinde, MS tanısı koyarken, demiyelinizan lezyonların sinir sisteminin farklı yerlerinde, farklı zamanlarda oluşturduğunun ("zaman ve mekan yayılımı" diye bilinen özelliklerin) gösterilmesinde, MR görüntülemenin değeri vurgulanmaktadır (Toğrol & Demir, 2016: 18).

MR görüntülemeye alternatif olarak kullanılan yöntem bulunmamakla birlikte teşhis için yardımcı araçlar geliştirmek için bazı akademik çalışmalar yapılmaktadır. Elektroensefalogram (EEG) sinyallerini ile yapılan bazı çalışmalarda MS ön tanısını konulmasına yardımcı olmak, MS'i sınıflandırmak için yardımcı araçlar önerilmiştir (Barrientos vd., 2018: 1; Karaca vd., 2021: 1).

MS teşhisi sırasında önemli bir araç olan beyin MR cihazları, farklı sekanslarda çekim yapabilmektedir. Bu sekansların en yaygın olanları T1w, T2w, PD, MPRage ve FLAIR'dir. Şekil 3.2'de MS'li bir hastanın MR görüntülerinin farklı sekanslarına örnekler görülmektedir. MR kesitlerinin çekim açısına göre alınan kesitleri (a) Sagittal (b) Aksiyel (c) Koronal Şekil 3.3'te görülmektedir. Çekimler tek açı üzerinden alınarak birleştirildiğinde 2B beyin görüntüsü oluşturulabilir, çekim izotropik olarak yapıldığında 3B beyin görüntüsü elde edilebilir.




(a)

(b)

(c)

**Şekil 3.2.** MS Kesitlerinde (a)PD (b)T2w (c)FLAIR Sekanslarında MS Lezyonları

T1w görüntülerinde yakın zamanda meydana gelen ataklarda oluşmuş (akut) veya çok gelişmiş lezyonlar kara delik formunda görüntülenir. T2w görüntülerinde daha önceki ataklarda meydana gelen kronik lezyonlar ve beyin boşluklarındaki alanlar beyaz parlamalar şeklinde görüntülenir. FLAIR görüntülerinde MS lezyonları kronik ve akut lezyonların farklı yoğunluklar ile ortaya çıkmasını sağlayarak görüntülenir (Khayati vd., 2008: 125). FLAIR görüntüler MS lezyonlarının bilgisayar destekli sistemler tarafından belirlenmesinde sıkça kullanılmaktadır (Cabezas vd., 2014: 160; Dachraoui vd., 2022: 3; SadeghiBakhi vd., 2022: 2).



(a)


(b)

(c)


**Şekil 3.3.** Farklı Açılardan, (a) Aksiyel, (b) Koronal, (c) Sagittal MR Kesit Örnekleri

MS hastalığının teşhisinde MR görüntüleri en önemli tanı aracı olmasına rağmen; hekimlerin incelemesi sırasında MS hastalığı nöromiyelitis optika (Lana-Peixoto vd., 2018: 53), akut serebral enfarktüs (Deguchi vd., 2018: 1033), akut yayılmış ensefalomyelit (Desse vd., 2018: 1789) gibi diğer beyaz cevher hastalıkları ile karıştırılabilmektedir. Şekil 3.4'te MR görüntülerinde fark edilebilen diğer beyin hasarlarına örnekler görülmektedir (Talo vd., 2019: 3). Bu hastalıklarının her biri için hekimlerin izlediği farklı protokoller bulunmaktadır. Ancak MR kesitleri incelendiğinde çoğunun MS lezyonlarına benzer olabileceği açıkça görülmektedir.

### Normal Beyin



### Serebrovasküler Hastalıklar



Akut İnme

İskemik İnme

Kronik Subdural  
Hematom

Orbital Kavernöz  
Hemanjiom

Damarsal Demans

### Neoplastik Hastalıklar



Gliom


Metastatik  
Adenokarsinom

Metastatik  
Bronkojenik Karsinom

Meninjiyom

Sarkom

### Dejeneratif Hastalık



Alzheimer


Huntington Hastalığı

Motor Nöron  
Hastalığı

Serebral  
Kalsifikasyon

Pick Hastalığı

### İltihaplı veya Bulaşıcı Hastalıklar



Multipl Skleroz

AIDS

Lime Hastalığı

Herpes Virüs Ensefaliti

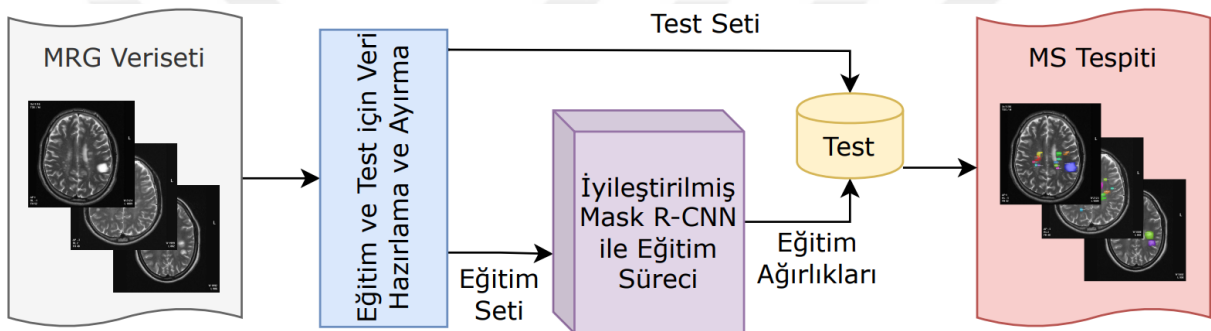
Deli Dana Hastalığı

Şekil 3.4. Çeşitli Beyin Hasarlarına Ait MR Görüntüleri

Kaynak:(Talo vd., 2019: 3)

#### 4. MS LEZYONLARININ MR GÖRÜNTÜLERİ ÜZERİNDE DERİN ÖĞRENME YÖNTEMLERİ İLE OTOMATİK TESPİTİ

MS lezyonlarının başarılı olarak tespitinin hastalığın teşhis ve tedavi sürecinde büyük öneme sahip olduğu tez çalışmasının önceki bölümlerinde ortaya koyulmuştur. Tez çalışmasının bu bölümünde, MR kesitleri üzerinde iyileştirilen derin öğrenme modeli (iMask R-CNN) kullanılarak MS lezyonların otomatik tespiti detaylandırılacaktır. Ayrıca bu bölümde, MS Lezyonlarının tespitinde kullanılan özgün ve açık verisetleri, geliştirme platformları, yararlanılan derin öğrenme modellerinin yapısı, tez çalışması kapsamında önerilen iMask R-CNN modelinin yapısı, yapılan eğitim ve test ortamlarda kullanılan unsurlar ve kullanılan tüm derin öğrenme modellerin farklı ortamlarda farklı verisetleri ile detayları ile sunulmuştur.



**Şekil 4.1.** Tez Kapsamında Önerilen Otomatik MS Lezyon Tespit Yaklaşımının Açık Blok Diyagramı

Tez kapsamında önerilen sistemin genel yapısının blok diyagramı Şekil 4.1’de görülmektedir. Sistemin ilk adımı, önerilen modelin ihtiyaç duyduğu formatta uygun verisetinin hazırlanması ile başlanmasıdır. Veriseti hazırlama işlemi, etiketlerin uygun dosya yapısında hazırlanması, eğitim ve test setlerinin ayrılmasını ifade etmektedir. İkinci adım, eğitim için ayrılan verisetinin iyileştirilmiş derin öğrenme modeli (iMask R-CNN) ile eğitiminin gerçekleştirilmesi ve ağırlıkların kaydedilmesi ile tamamlanır. Üçüncü adım ise, elde edilen en uygun model ağırlıklarının test için ayrılan veri kümesi ile deneysel analizlere tabi tutulması ve en iyi sonuçların elde edilmesi ile tamamlanır. Son adımda ise, elde edilen en iyi ağırlık değerleri kullanılarak test kümesi üzerinde MS lezyonlarının otomatik tespiti ve bölütlemesi gerçekleştirilir.

## **4.1. Materyal ve Yöntem**


Tez çalışması kapsamında, MS lezyonlarının tespiti için Akdeniz Üniversitesi Tıp Fakültesinden toplanan verilerle özgün bir veriseti hazırlanmış ve herkesin kullanımına açık dört farklı MS veriseti kullanılarak derin öğrenme modellerin aracılığıyla deneysel çalışmalar gerçekleştirilmiştir. Çalışma kapsamında hazırlanan özgün veriseti MSAkdeniz ismi ile sunulmuştur. MS lezyonlarının tespiti için kullanılan açık verisetleri ise eHealth, Ljubljana, ISBI2015 ve MICCAI 2008'dir.

### **4.1.1. Verisetleri**

Tez çalışması kapsamında derin öğrenme modelleri ile MS lezyonlarının otomatik tespiti için deneysel çalışmalarda, tez kapsamında hazırlanan özgün veriseti MSAkdeniz başta olmak üzere önerilen yöntemlerin doğruluğunu ortaya koymak için eHealth, Ljubljana, ISBI2015 ve MICCAI 2008 açık verisetleri kullanılmıştır.

#### **4.1.1.1. MSAkdeniz Veriseti**


MSAkdeniz veriseti, Akdeniz Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurulu'nun KAEK-461 sayılı kurul kararı ile 23.06.2021 tarihinde alınan onay ile bu tez çalışması kapsamında hazırlanan özgün verisetidir. Veriseti 52 gönüllü hastanın 2 periyodik muayenesinde sagittal açıdan alınmış MR görüntülerini içermektedir. Çekimler 1 mm aralıklarla Siemens 3T cihaz ile izotropik olarak yapılmıştır. Şekil 4.2'de MSAkdeniz verisetinde bulunan aynı hastanın iki farklı periyodik muayenesinden alınmış MR görüntülerinden örnekler sunulmuştur. Burada, A1-A2-A3 bir hastanın bir çekimdeki kesitlerini, B1-B2-B3 ise aynı hastanın periyodik olarak bir sonraki çekimine ait kesitlerini göstermektedir. Verisetindeki MR çekimleri izotropik yapıldığı için, örnek MR görüntülerinden görüleceği gibi aynı taramada, sagittal düzleminde alınmış A1-B1 kesitleri yüksek çözünürlüğe sahipken, A2-B2 aksiyel ve A3-B3 koronal açıdan kazanılmış kesitler düşük kalitede oluşmuştur.



**Şekil 4.2.** MS Akdeniz Verisetinden Sagital (A1, B1), Aksiyel (A2, B2) ve Koronal (A3, B3) Açından Örnek MR Görüntüleri

#### 4.1.1.2. eHealth Laboratuvarı MS Veriseti


Bu veriseti, MR görüntüleri üzerinde MS tespiti için Kıbrıs Üniversitesinin eHealth Laboratuvarı tarafından bilimsel çalışmalar için oluşturulmuştur (Loizou, 2012). 38 hastanın MR görüntülerini barındıran veriseti, hastaların hem ilk muayene görüntülerini hem de 6-12 aylık periyodik muayenelerinde alınan görüntülerini içermesinin yanında uzmanlar tarafından işaretlenmiş lezyonları (maskeleri) da içermektedir. Şekil 4.3'te eHealth laboratuvarının MS verisetinden örnek MR görüntüleri görülmektedir. Burada A, B, C farklı hastaları temsil etmektedir ve görüntülerin tamamı aksiyel açıdandır. A1-B1-C1 hastaların ilk MR tarama görüntülerini; A2-B2-C2 ise aynı hastaların 6 veya 12 aylık periyodik muayenesinden alınan yakın konumuna ait MR görüntülerini göstermektedir. eHealth verisetinde 38 hastadan alınan toplamda 1838 MR görüntüsü bulunmaktadır. Ayrıca MR görüntüleri üzerindeki lezyonların sınırları(maskeler) uzmanlar tarafından işaretlenmiştir.



**Şekil 4.3.** eHealth Laboratuvarı MS Verisetinden Örnek MR Görüntüleri. (A, B, C) Farklı Hasta Taramaları. (A1-B1-C1) Hastaların İlk MR Tarama Görüntüleri, (A2-B2-C2) ise Aynı Hastaların 6 veya 12 Aylık Periyodik Muayenesinden Alınan Yakın Noktanın MR Görüntüleri

#### 4.1.1.3. Ljubljana Üniversitesi UMCL Veriseti

Bu çalışmada kullanılan diğer açık veriseti olan UMCL veriseti, Ljubljana Üniversitesi Tıp Merkezi tarafından hazırlanan ve (UMCL) beyaz cevher lezyonu (WMH) segmentasyonları içeren MS hastalarının 3B MR görüntülerinden oluşmaktadır (Lesjak vd., 2018: 52). Bu verisetinde, 30 katılımcıya ait MS lezyonları işaretlenmiş 3B MR görüntüleri bulunmaktadır. Her hastanın MR taraması T1w, T2w ve 3B FLAIR sekanslarından oluşmaktadır. MR görüntüleri üzerindeki lezyonlar uzmanlar tarafından işaretlenmiş ve katman olarak eklenmiş bir yapıya sahiptir. Şekil 4.4'te UMCL verisetinden alınan A, B, C ile farklı hastaların temsil edildiği ve aynı hastaların aksiyel (A1-B1-C1), koronal (A2-B2-C2), sagittal (A3-B3-C3) düzlemde MR görüntülerinden örnekler sunulmuştur. Bu tez çalışmasında, UMCL verisetinin segmentasyon prosedürleri gereği yüksek çözünürlüğe sahip sagittal açıdan kesitlere ait FLAIR sekansındaki görüntüler kullanılmıştır.




**Şekil 4.4.** UMCL Verisetinden Alınan ve (A, B, C) ile Farklı Hastaların Temsil Edildiği Sırayla Aksial (A1-B1-C1), Koronal (A2-B2-C2) ve Sagittal (A3-B3-C3) Düzlemde MR Kesit Örnekleri

#### 4.1.1.4. ISBI 2015 Veriseti

ISBI 2015 veriseti, 12. Uluslararası Biyomedikal Görüntüleme Sempozyumu (ISBI) kapsamında düzenlenen bir yarışma verisetidir (Carass vd., 2017: 77). ISBI2015 veriseti, eğitim setinde 5, test setinde ise 14 olmak üzere toplam 19 hastanın taramalarını içermektedir. Verisetinde tüm hastaların farklı periyotlarda çekilmiş T1w, T2w, PD ve FLAIR modalitedeki görüntüleri bulunmaktadır. Verisetinin ön işlemden geçirilmiş hali için eğitim kümesinin MS lezyonları uzmanlar tarafından işaretlenerek sunulmuştur. Ancak test kümesinin MS lezyon maskeleri herkese açık hale getirilmemiştir. Yarışma kapsamında takımlar farklı periyotlarda alınmış MR görüntüleri üzerinde lezyon segmentasyonu yapmıştır. Sonuç segmentasyonları

NifTI formatında yarışma sitesine yüklenerek doğruluk skoru hesaplamaları yapılmaktadır. Verisetinde, eğitim seti ile yayınlanan maskeler ön işlemlerle görüntüler ile uyumludur. Bu tez çalışmasında, bu verisetinin eğitim kümesinde bulunan 5 hastanın ön işlemle geçirilmiş FLAIR modalitedeki görüntüleri kullanılmıştır. Şekil 4.5'te ISBI2015 verisetinden alınan ve A ve B farklı hastaları temsil etmek üzere aynı MR çekimindeki farklı kesitlere örnekler sunulmuştur. Burada lezyon alanlarının kesitlere göre farklılıkları açıkça görülmektedir.




**Şekil 4.5.** ISBI2015 Verisetinden Alınan, A ve B ile Farklı Hastaların Temsil Edildiği Aynı Çekimdeki Farklı MR Görüntüleri

#### 4.1.1.5. MICCAI2008 MS Lezyon Bölütleme Veriseti

Bu veriseti, 11. Uluslararası Tıbbi Görüntü Hesaplama ve Bilgisayar Destekli Müdahale Konferansı (MICCAI2008) kapsamında MS lezyonlarının tespiti için hazırlanan bir yarışmanın verisetidir (Styner vd., 2008: 3). MR görüntüleri Boston Çocuk Hastanesi (CHB) ve Kuzey Karolina Üniversitesi (UNC) tarafından toplanmıştır. UNC vakaları Siemens 3T Allegra MRG tarayıcısında 1 mm kesit kalınlığı ve 0.5 mm düzlem içi çözünürlüğü ile elde edilmiştir. Verisetinin eğitim kümesi ve test kümesi internet kaynaklarında kullanıma sunulmuştur ve içinde 2B T1w, 2B T2w ve 3B FLAIR MR modalitelerinde görüntüler bulunmaktadır. Ayrıca eğitim kümesindeki 20 hastanın uzmanlar tarafından etiketlenmiş maskesi de vardır. Bu tez çalışması kapsamında, verisetindeki eğitim kümesindeki 20 hastaya ait 3B FLAIR MR görüntüleri ve MS lezyonlarının maskeleri kullanılmıştır. Şekil 4.6'da MICCAI2008

verisetinden UNC tarafından alınan farklı hastaların (A1-B1-C1) ve CHB tarafından alınan farklı hastaların (A2-B2-C2) MR kesiti örnekleri sunulmuştur.




**Şekil 4.6.** MICCAI2008 Verisetinden UNC Tarafından Alınan Farklı Hastaların (A1-B1-C1) ve CHB Tarafından Alınan Farklı Hastaların (A2-B2-C2) MR Görüntüleri

#### 4.1.2. Etiketlerin Organizasyonu ve Düzenlemesi

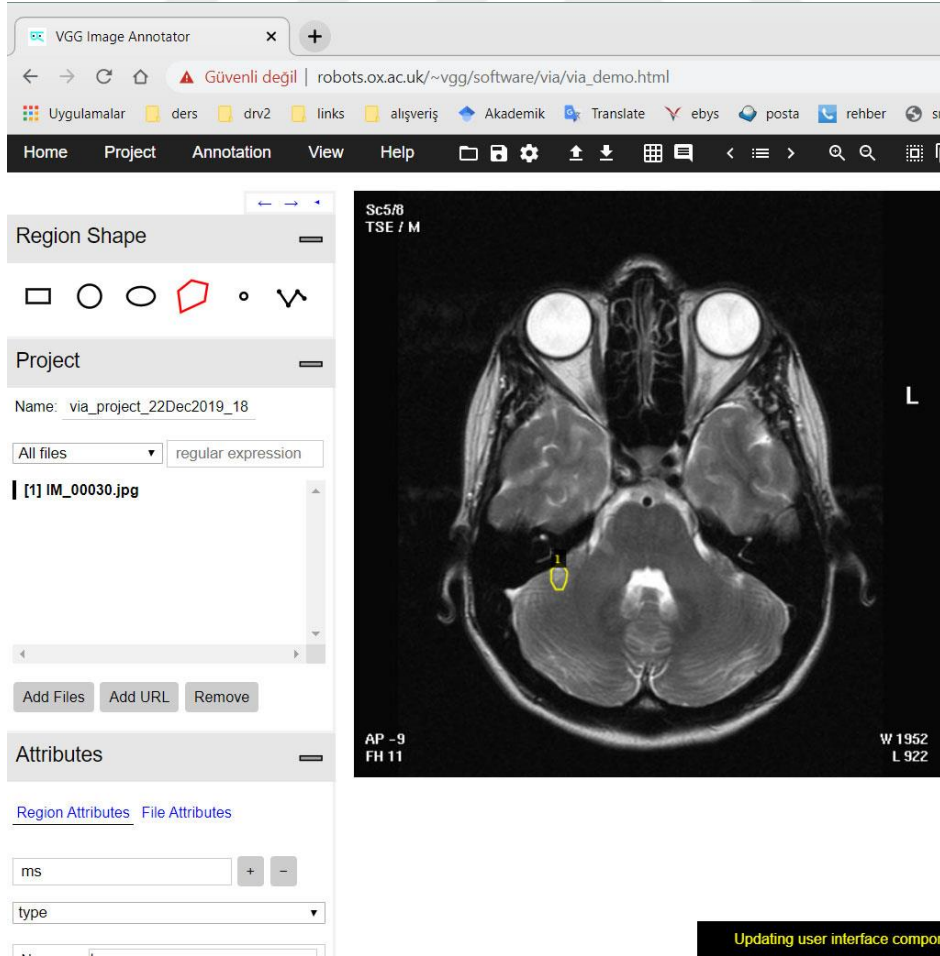
Tez çalışması kapsamında, MS lezyonlarının tespiti için önerilen derin öğrenme tabanlı yöntem için kurgulanan deneysel çalışmalarda toplamda biri özgün olmak üzere toplamda beş farklı veri seti kullanılmıştır. MSAkdeniz, UMCL, ISBI2015 ve MICCAI2008 veri setleri NifTI formatında MR görüntülerine ve aynı formatta uzman etiketlerine sahiptir. Bu veri setlerinde görüntüler hazırlanan Python program parçası ile taranarak, MS lezyonu barındıran MR kesitleri ve uzman etiketlerinin kesitleri JPG formatında görseller olarak ayrılmıştır. Eğitim ve test verileri bu görüntüler içerisinde rastgele seçilmiştir. Maskelerin bulunduğu görüntülerde ise, OpenCV kullanılarak sınırlar belirlenmiş ve belirlenen sınırlardan VGG formatında JSON maske etiketleri elde edilmiştir.

eHealth Laboratuvarı veri setinde ise, MS lezyonu etiketleri .plq formatında sunulmuştur. Ancak bu format çalışmada kullanılan sistem ile uyumsuz olduğu için MATLAB ortamında görüntüler JSON formatına dönüştürülmüştür. Şekil 4.7’de gösterilen yapı ile .plq uzantılı dosyalar tek tek okunarak VGG 1.6 yapısında JSON formatına çevrilmiştir.



**Şekil 4.7.** .plq Uzantılı Dosyalarının VGG Formatına Uyumlu JSON'a Çevrilmesi

Tüm verisetlerinde uygun veri dönüştürme işleminin sonucunda önerilen derin öğrenme yöntemi iMask R-CNN ve Mask R-CNN için uygun formatta etiketler elde edilmektedir. Ayrıca, görüntülerde MS lezyonlarını gösteren maskeler için de aynı prosedürler gerçekleştirilerek, süreç tamamlanmıştır. Bu prosedürler arayüzü Şekil 4.8'de görülen açık kaynak kodlu görüntü etiketleme uygulaması VGG Image Annotator ile yapılmıştır (Dutta vd., 2016).



**Şekil 4.8.** VGG Image Annotator ile MS Lezyon Etiketleme Prosedürleri


### 4.1.3. Veri Arttırma (Data Augmentation)

Derin öğrenme modellerinde eğitim sürecinde hatayı sürekli azaltmak oldukça kritiktir. Görüntü tabanlı modellerde hatayı azaltmak ve doğruluk başarımını yükseltmek için en başta veri artırılma (data augmentation) gelmektedir. Görüntü tabanlı veri artırma işlemleri, farklı veri dönüşümlerini sağlayarak, ağ üzerinde bir genelleştirme oluşturmaktadır ve ağın başarımlarını yükseltmektedir. Literatürde veri artırımını sağlamak için, yaygın olarak kullanılan birçok veri artırma tekniği bulunmaktadır. Çevirme, başka bir görüntü uzayına aktarma, kesme, döndürme, öteleme, gürültü ekleme bunlardan bazılarıdır (Kusrini vd., 2020: 1).

Tez çalışması kapsamında kullanılan U-Net ağının başarımlarını için veri artırma büyük öneme sahiptir. U-Net modellerinde yapılan eğitim ve testlerde, görüntüler üzerinde veri artırma için Keras çatı uygulaması içinde bulunan veri artırma kütüphanesi (Chollet F., 2022: 1) kullanılmıştır. Veri artırma için *width shift range=0.05*, *height shift range=0.05*, *fill mode='nearest'* parametreleri uygulanmıştır. Tez çalışması kapsamında, MR görüntülerinde ve maskelerde açılı döndürme işlemleri sonucunda bozulma olduğundan, sadece dikey ve yatay kaydırma işlemleri uygulanmıştır. Tüm verisetlerinde veri artırma ile hem eğitim hem de test kümelerindeki görüntü sayıları yaklaşık dört katına kadar çıkarılmıştır ve her bir verisetinde veri artırımı uygulanmış görüntüler Şekil 4.9'da sunulmuştur. Burada yapılan veri artırma işlemi uygulanmış görsellerden rastgele seçilmiş örnekler görülmektedir.

### 4.1.4. Derin Öğrenme Platformları

Tez çalışmaları kapsamında MS lezyonlarının otomatik tespiti için iki farklı platform kullanılarak önerilen ağın eğitim ve testleri gerçekleştirilmiştir. Bu platformlar Tensorflow tabanlı Keras (Keras, 2022) ve Pytorch tabanlı Detectron2'dir (Detectron2, 2022). Çalışmalar sonucunda elde edilen deneysel sonuçlara göre bu iki platform bazı ölçütlere göre karşılaştırılmıştır. Bu bölümde tez kapsamında yararlanılan derin öğrenme platformlarının özellikleri ve çalışma prensipleri açıklanmıştır.

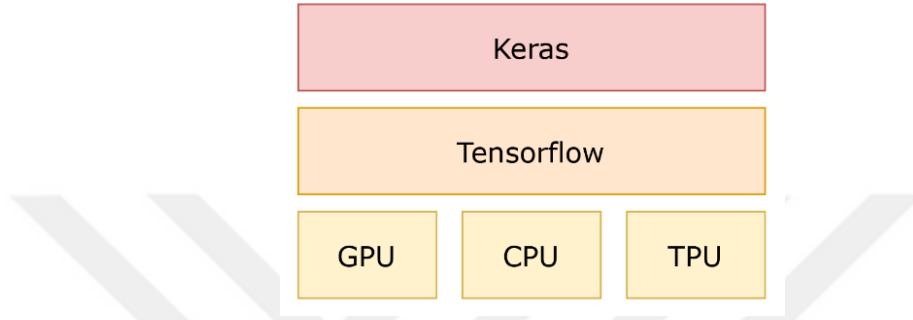


**Şekil 4.9.** MSAkdeniz(a), eHealth(b), UMCL(c), ISBI2015(d) ve MICCAI2008(e) Verisetlerinde Veri Artırımı Yapıldığında Elde Edilen Örnek MR Görüntüleri

#### 4.1.4.1. Tensorflow 2.0 ve Keras

Tensorflow derin öğrenme modelleri geliştirmek için kullanılan bir çatı uygulamadır. Derin öğrenme çalışmalarında işlemci, ekran kartı gibi işleçlerin dağıtık bir yapıda en verimli şekilde çalıştırılmasına imkan sağlar (Abadi vd., 2016: 14; Singh & Manure, 2020: 5). Keras

bağımsız bir derin öğrenme kütüphanesi değildir. Tensorflow 2.0 ile beraber sunulan Keras API sayesinde birçok hazır derin öğrenme modeli hızlı ve kolayca kullanılabilir. Aynı zamanda yeni modeller hızla geliştirilebilir (Atienza, 2020: 2). Keras ve Tensorflow Google tarafından hizmete sunulmuştur. Şekil 4.10'da Keras, Tensorflow ve donanım ilişkisi görülmektedir. Burada, Keras ortamının TensorFlow aracılığı ile derin öğrenme algoritmalarını kullanırken CPU, GPU ve TPU donanımlarına erişerek yoğun hesaplama işlemlerini yüksek kapasite ve hızla gerçekleştirebildiğini temsilen gösterilmiştir.




**Şekil 4.10.** Tensorflow ve Keras Platformunun Donanım ile İlişkisi

#### **4.1.4.2. PyTorch ve Detectron2**

Detectron2, Facebook AI Research (Facebook Yapay Zeka Araştırma Birimi) tarafından son teknoloji nesne algılama algoritmalarını uygulayan yeni nesil yazılım sistemidir (MetaAI, 2022). Aynı zamanda Detectron2, PyTorch platformu üzerinde çalışan, gelişmiş bir yapay zeka platformudur (Detectron2, 2022). Platform üzerinde 80'den fazla yapay zekâ mimarisi üzerinde geliştirme, eğitim ve test işlemleri yapılabilmektedir. Tez çalışması kapsamında, Detectron2 üzerinde tahmini özel bölgeleri belirleme işlemlerinde iMask R-CNN modeli kullanılarak farklı omurga yapısında çeşitli eğitimler ve testler uygulanmıştır.

#### **4.1.5. Derin Öğrenme Modelleri**

Standart derin öğrenme modellerinde kullanılan bazı temel yapılar bulunmaktadır. Derin öğrenme modellerinde kullanılan en yaygın ağ modeli evrimsel sinir ağı (CNN)'dir. CNN'nin genel yapısı Şekil 4.11'de görülmektedir. CNN yapısı, genellikle özellik çıkarımı ve sınıflandırma ana bölümlerinden oluşmaktadır (Weimer vd., 2016: 416). Özellik çıkarımı konvolüsyon (convolutional), doldurma (padding), ReLu ve havuzlama (pooling) adımlarının modele göre belirlenen tekrarından meydana gelir. Sınıflandırma katmanı ise düzleştirme (flatten layer), tam bağlantılı katman (fully connected layer, FCL) ve maksimum seçim (softmax) katmanlarından oluşmaktadır (Albawi vd., 2017: 1; Nielsen, 2015: 169).



**Şekil 4.11.** Standart CNN Yapısının Katmanlı Örnek Gösterimi

ESA'nın giriş katmanında, giriş verisi genellikle tek kanallı (gri skala) görüntülere çevrilerek konvolüsyon katmanı tarafından evrişim işlemleri başlatılır. Ardından konvolüsyon katmanında veri üzerinde çeşitli filtreler gezdirilerek farklı açılardan çıktılar sağlanmaktadır (Ravi vd., 2016: 390). Sonuçta uygulanan filtre sayısı kadar çıktı alınır. Konvolüsyon katmanından alınan veriler derin öğrenme katmanlarında ilerledikçe, giriş görüntüsü veri matrisleri haline dönüşmektedir (Kalchbrenner vd., 2014: 6; Sarıgül vd., 2019: 281). Veri matrislerinde negatif ve eksik değerler ile karşılaşılabilir. Eksik değerlerin çözümü olarak doldurma işlemi uygulanmaktadır. Bu veri matrislerinde uygulanan filtreler ve doldurma işlemi sonucunda negatif veriler ile de karşılaşılabilir (Nielsen, 2015: 169). Negatif değerli veriler görseller üzerinde bulunamayacağı için aktivasyon fonksiyonu olarak ReLu katmanı ile negatif değerler 0 (sıfır)'a çekilir. Katmanlar arası geçişlerde veri yoğunluğunun anlamlı hale getirilmesi ve matris sayısının artmasına karşılık, matris boyutunun küçültülmesi için havuzlama işlemi yapılır (Sun vd., 2017: 96). Havuzlama işlemi, veri matrislerinde belli çapta karelere bakarak maksimum veya ortalama alınarak yeni matrisler oluşturularak gerçekleştirilir. Bu süreç sonucunda veri uzatılmış bir şerit matrisi haline getirilir (Krizhevsky vd., 2012: 5; Özkan & Ülker, 2017: 88). Kullanılan modele göre bu işlemler geri doğru tekrarlanarak veya tam bağlantılı katmana yönlendirilerek veri matrisinden ayrıştırma gerçekleştirilir. Tam bağlantılı katman esasen bir sinir ağı yapısıdır (Wu, 2016: 173). Bu katmanda düzleme çekilmiş veri giriş olarak kullanılır ve kendi içinde gizli katmanlar aracılığı ile değerlendirilir. Çıkış katmanında ise sınıflara göre ağırlıkları belirlenir. Sınıflandırma (softmax) katmanına gönderilen bu veriler en yüksek oranda aldığı değere göre belirlenerek sınıf seçiminin yapılması sağlanır (Liu vd., 2016: 2). Tam bağlantılı katmanın başarımını arttırmak için bazı noktalarda çıkarma (dropout) işlemi uygulanabilir (Wu & Gu, 2015: 2). Bu işlem modelin planlamasına göre bazı durumlarda, bazı gizli katman nöronlarının iptal edilmesi olarak açıklanabilir. Bu sayede tam bağlantılı katmanın başarımını arttırmak mümkün olmaktadır. Derin öğrenme

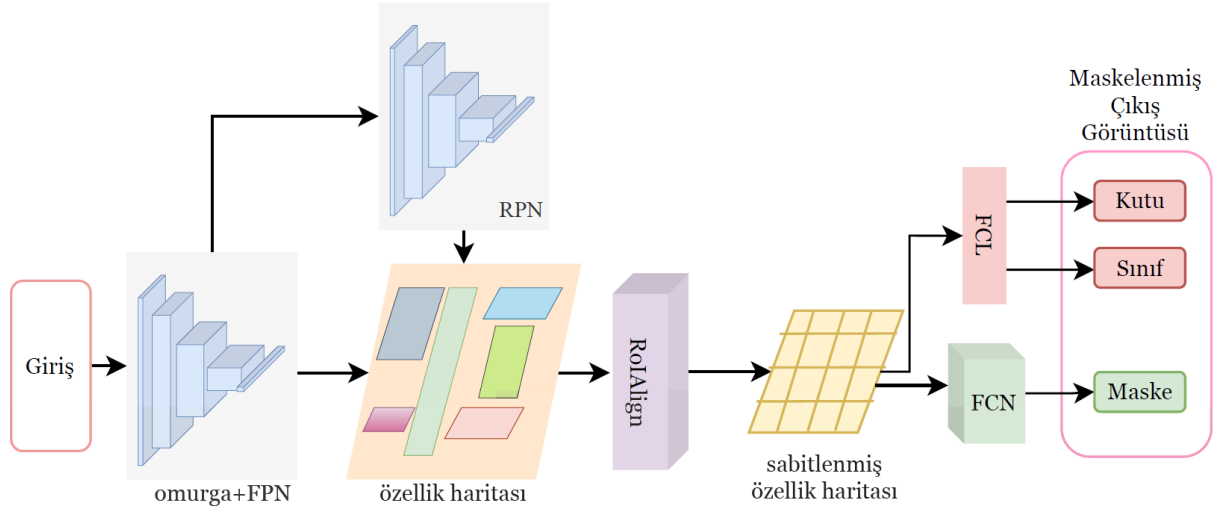
mimarileri bu parçaların farklı kombinasyonlarda birleştirilmesi sonucunda ortaya çıkmaktadır. Sonuç olarak, CNN modellerinin oluşturulmasında detaylı planlama ve hesaplamalar sonucunda kurgulama gerektiği açıktır.

Tez çalışması kapsamında, dört farklı derin öğrenme modeli kullanılmıştır. Bu modellerden ikisi literatürde MS lezyonlarının tespiti için sıkça kullanılan U-Net ve Mask R-CNN'dir. Ayrıca tez kapsamında önerilen İyileştirilmiş Mask R-CNN (iMask R-CNN) modeli ResNet101 ve ResNeXt101 omurga yapıları ile iki yapıda kullanılmıştır ve karşılaştırılmıştır.

#### **4.1.5.1. Mask R-CNN**

Derin öğrenme modellerinin ortak altyapısı olarak CNN mimarisi kullanılmaktadır. CNN mimarisinin temel yapısı yukarıda açıklanmıştır. CNN mimarisinin temel yapıları birleştirilerek bazı özellikler eklenerek yeni derin öğrenme modelleri geliştirilmektedir.

CNN üzerinden geliştirilen Bölge Temelli CNN (R-CNN, The Region-based CNN), veri matrisleri üzerinde nesnelere bulunma ihtimali olan sınırlayıcı kutuları belirleyerek veriyi kutulara ayıran (segmente eden) ve kutuların içinde olası nesnelere bulmak için algılama algoritmasını üzerinde çalışan bir derin öğrenme modelidir. (Girshick vd., 2014: 1). R-CNN'nin çalışma yapısındaki yoğunluktan dolayı donanımsal ihtiyaçlarını azaltmak, hızını ve başarısını arttırmak için Hızlı Bölge Temelli CNN (Fast Region-based Convolutional Network , Fast R-CNN) isimli model geliştirilmiştir (Girshick, 2015: 1440). Bu modelde temel CNN işlemlerinden sonra iki farklı tam bağlantılı katman kullanılarak bölge tahmini işleminin ayrıca yapılması amaçlanmıştır. Bu işlem sayesinde tahminen önemli bölge (Region of Interest, RoI) katmanı elde edilmiştir. Uçtan uca çalışsan Fast R-CNN üzerinde yapılan geliştirme ile yapıya bölge teklif ağı (Region Proposal Network, RPN) eklenerek modelin bölgeleri içinde ayrı bir ağ üzerinden belirlenmesinin yolu açılarak Daha Hızlı Bölge Temelli CNN (Faster R-CNN) geliştirilmiştir. RPN tarafından belirlenen RoI alanları üzerinde kullanıcı tarafından belirlenen bölme alanlarına göre ve maksimuma göre havuzlama işlemi yapılarak matris dizilimi gerçekleştirilir ve RoI-Havuzlama (RoIPool) olarak isimlendirilir. (Ren vd., 2015: 3).



**Şekil 4.12.** Mask R-CNN Mimarisinin Genel Yapısı

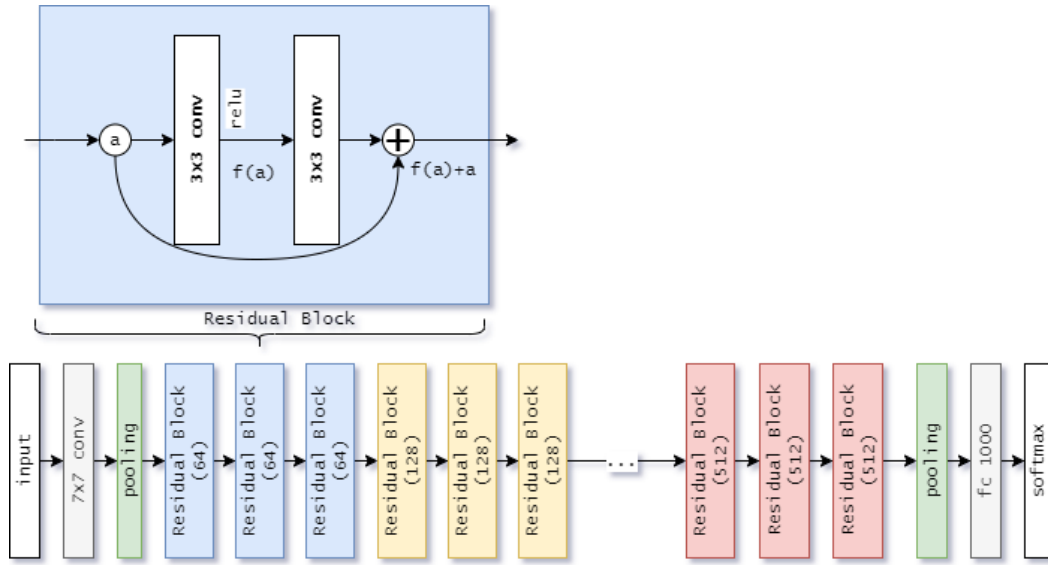
R-CNN mimarilerinin gelişiminde güncel son yöntem Şekil 4.12’de genel diyagramı görülen Maskeli (Maske Tabanlı) Bölgesel Evrimsel Sınır Ağı (Mask Region-based Convolutional Neural Network, Mask R-CNN)’dir. Mask R-CNN temel olarak iki aşamadan oluşmaktadır. Birinci aşamada Faster R-CNN mimarisinin temel unsuru olan RPN’yi kullanarak bölge tespitleri yapılmaktadır. İkinci aşamada önemli bölge olarak belirlenen her alan için nesne sınırlarına göre, ikilik sistemde maskeler oluşturulmaktadır. Faster R-CNN’de kullanılan RoIPool işlemi, Mask R-CNN’de tahmini önemli bölge hizalama (RoIAlign) ile değiştirilmiştir. RoIPool işleminden farklı olarak, RoI olan alanlarda belirlenen bölgeler üzerinde dört nokta arasında hizalama yapılarak maksimum noktanın alınması ile RoIAlign işlemi tamamlanmaktadır (He vd., 2017: 2963). Ayrıca Fast R-CNN ve Faster R-CNN’den farklı olarak özellik piramit ağı (Feature Pyramid Network, FPN)’de Mask R-CNN için standart olarak kullanılmaktadır. FPN yapısında her katmanda özellik çıkarımı yapıldığı için sonuçta çıkarılan özellik haritası daha detaylıdır (Lin vd., 2017: 2119). İkinci aşamada ise, maskelerin çıkarılması için küçük bir tam evrimsel ağ (Fully Convolutional Network, FCN) kullanılmaktadır. FCN ile önemli olarak belirlenen alanlardan gelen her alan için ağ çalıştırılır ve maske üretimi gerçekleştirilir (Long vd., 2015: 3432; Shelhamer vd., 2016: 642)

Mask R-CNN, Fast R-CNN ve Faster R-CNN modellerinde özellik çıkarımı için çeşitli omurga yapıları kullanılmaktadır. Bu omurga yapılarına ResNet ve ResNeXt mimarileri örnek olarak verilebilir.

#### 4.1.5.2. ResNet ve ResNeXt Omurga Yapıları

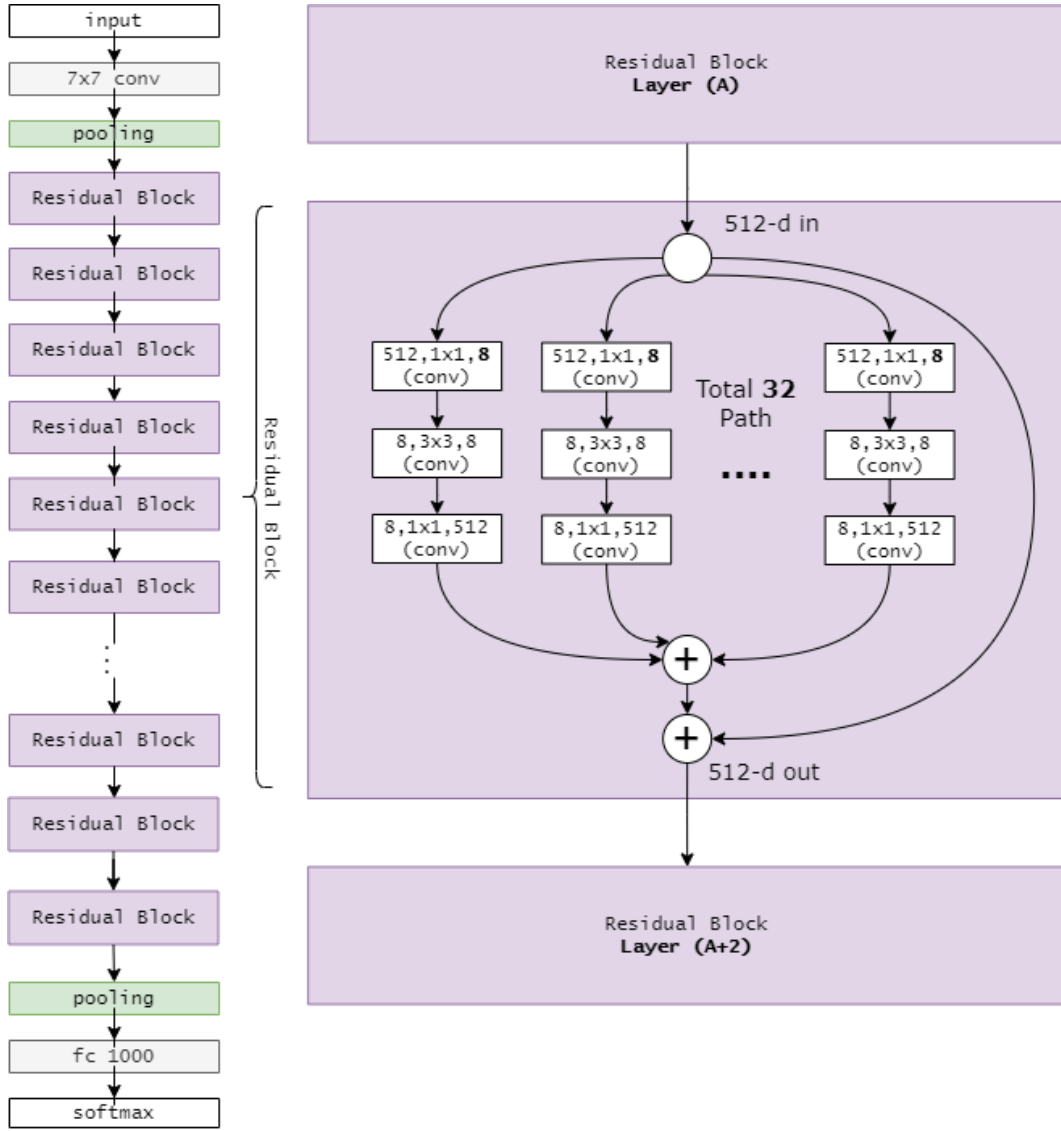
Mask R-CNN yapısı içerisinde çeşitli omurga yapıları kullanılmaktadır. Bu omurga yapıları öncelikle özellik çıkarımı için, sonra belirlenen kutulardaki (bounding box) nesnelere

bölütlemesi için kullanılmaktadır. Bu tez çalışmasında, ResNet ve ResNeXt yapıları, Mask R-CNN'nin omurga yapısında kullanılmak üzere seçilmiştir. CNN yapılarının geliştirilmiş bir birleşimi olan ResNet mimarisi blok yapılarından oluşmaktadır. Bloklar içinde doğrusal evrişim işlemleri ve ReLu işlemlerinin yanı sıra, atlamalı toplam alınarak giriş ile blok işlemlerinin sonuçlarının birleştirilmesi ile çıkış elde edilmektedir (Targ vd., 2016: 1). Şekil 4.13'te ResNet mimarisinin genel yapısı görülmektedir. Kullanılan blok adedi ağın isminin yanında belirtilerek ifade edilir. ResNet50, ResNet101 ve ResNet151 ağ yapıları omurga olarak çok sık kullanılan ResNet formlarıdır.



**Şekil 4.13.** ResNet Mimarisinin Genel Blok Yapısı

Mask R-CNN içerisinde kullanılan omurga yapılarından en yaygınlarından biri ResNet'tir. ResNeXt, bu ağ yapısının yenilenerek kardinalite ve boyut genişlemesi yapılması ile oluşturulmuştur (Xie vd., 2017: 1495). ResNet mimarisi artık bloklardan oluşmaktadır ve bu yapıda konvolüsyon işlemi tek bir kanal üzerinden yüksek sayıda filtre ile uygulanmaktadır. ResNeXt mimarisinde ise, artık blokların içinde yeni bir yapı oluşturulmuştur ve konvolüsyon işlemleri belirlenen sayıda kanal üzerinde nispeten daha küçük sayıda filtre ile uygulanmaktadır. ResNeXt ağları ifade edilirken, kardinalite sayısı, blok üzerinde konvolüsyon işlemleri için belirlenen yol sayısını; genişlik ise konvolüsyon işlemleri sırasında uygulanan filtre sayısını ifade etmektedir. Şekil 4.14'te kardinalitesi 32, genişliği 8 olan bir ResNeXt ağının blok içerisindeki yapısı görülmektedir.




Şekil 4.14. 32x8d ResNeXt Omurgasının Blok Yapısı

#### 4.1.5.1. U-Net

İki ana bölümden oluşan U-Net mimarisi görüntü bölütleme ve nesne tespitinde yaygın olarak kullanılan bir derin öğrenme yapısıdır. U-Net mimarisinin birinci bölümü kodlayıcı/küçülme yolu ve ikinci bölümü çözücü/genişleme yolu olarak tanımlanabilir (Ronneberger vd., 2015: 4). Şekil 4.15'te görülen U-Net modelinin mimari yapısı, kodlayıcı/küçülme yolundan (sol taraf) ve çözücü/genişleme yolundan (sağ taraf) oluşur. Bu yapı U şekilli mimariyi temsil etmektedir. Kodlayıcı/küçülme yolu, iki tane konvolüsyon işlemi, ReLu ve alt örnekleme için havuzlama işlemlerinden oluşur. Her alt örnekleme adımında, özellik kanallarının sayısı ikiye katlanır ( $2^n$ ) (Li vd., 2018: 3956). Çözücü/genişleme yolunda bulunan katmanlar ise, kodlayıcı/küçülme işleminin son adımından itibaren kanallarının sayısını yarıya indiren bir evrişimden ("yukarı evrişim") ve kodlayıcı/küçülme

yolundaki aynı seviyedeki katmandan kırılmış özellik haritasının birleştirilmesi ile oluşur. Her bir evrişimin ardından ReLu işlemi uygulanır. Son katmanda özellik haritasına istenen sayıda sınıfa eşlemek için yeniden evrişim uygulanır. Çıkış katmanı elde edilen bölütleme de aranan sınıf adedince ağırlık sonuçlarını sunar.

Bu tez çalışmaları kapsamında MS lezyonlarının tespiti için U-Net modeli kullanılarak eğitim ve testler gerçekleştirilmiştir ve elde edilen sonuçlar diğer yöntemler ile karşılaştırılmıştır



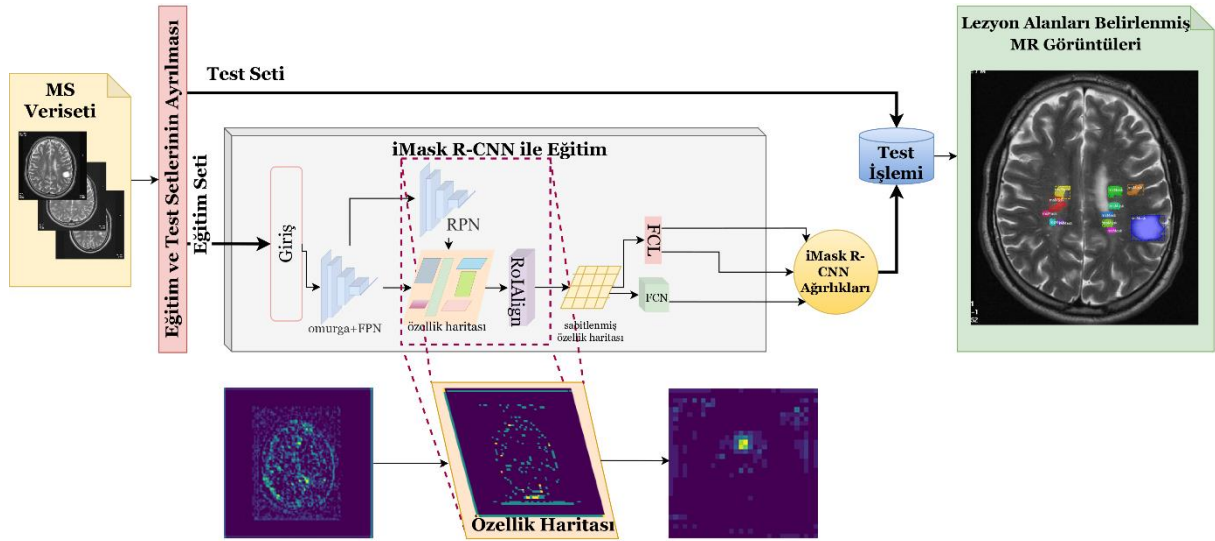
Şekil 4.15. U-Net Derin Öğrenme Modelinin Mimari Yapısı

#### 4.1.6. iMask R-CNN ve Lezyon Tespit Süreci

Tez çalışmaları kapsamında hazırlanan derin öğrenme modeli Mask R-CNN mimarisi üzerinde yapılan iyileştirmeler ile MS lezyonlarının tespiti için özel hale getirilmiştir ve iMask R-CNN olarak adlandırılmıştır. Mask R-CNN mimarisi önceki bölümlerde bahsedildiği gibi iki aşamalı bir yapı ile çalışmaktadır. İlk aşamada RoI alanlarının dağıtımı, RoIAlign ile pozitif RoI'lerin ve muhtemel lezyon alanlarının belirlenmesi yapılır. Bu süreçte lezyon bulunma ihtimali olan bölgeler belirlenmektedir. İkinci aşamada ise; lezyon olma ihtimali olan bölgelerin sınır alanları, sınıflandırmaları ve maske çıkarım işlemleri gerçekleştirilir.


Mask R-CNN'nin temel yapısında bulunan RoI dağıtım işlemi sınıflandırma doğruluğunu azaltan birçok alakasız RoI üretilebilir. Mask R-CNN'deki sınıflandırma, üretilen maskelerle yakından ilişkili olduğundan, RoI'lerin doğru ve uygun şekilde tahmin edilmesi gerekmektedir. MS lezyonlarının çok küçük veya çok büyük boyutlarda bulunduğundan, her iki lezyon tipine de uyum sağlayabilecek bir RoI sistemi kurulması gerekmektedir. Bu nedenle tez kapsamında değişen lezyon boyutlarına kolayca uyum sağlamak için Mask R-CNN'de bulunan RoIAlign aşamasındaki RoI dağıtım aşaması iyileştirilmiştir. Şekil 4.16'da görülen

blok diyagramında yapılan iyileştirme ile eğitim ve test sürecinin detayları görülmektedir. Burada MS verisetinin ilk aşamada veri hazırlama ve eğitim / test olarak dağıtım süreci görülmektedir. Eğitim veriseti iMask R-CNN ile eğitim süreçlerine tabi tutulmaktadır. Bu süreç içerisinde RoIAlign yapısında yapılan iyileştirme de kullanılarak sistemin en doğru lezyon seçimlerini yapması için gerekli ağırlıklar belirlenmektedir. Ardından elde edilen ağırlıklar test kümesi olarak ayrılan veriseti ile testlere tabi tutulmakta ve en başarılı eğitim ağırlığı bu aşama sonucunda seçilmektedir. Elde edilen en başarılı eğitim ağırlığı ile MS lezyon alanlarının yüksek başarıyla tespiti mümkün olmaktadır.




**Şekil 4.16.** Tez Kapsamında Önerilen iMask R-CNN Mimarisinin Yapısı


Mask R-CNN modelinin üzerinde yapılan iyileştirme ile RoIAlign işlemi aşamasında çalışma sistemi değiştirilmiştir. Genel kullanımda RoI belirlemede 32x32 piksel alanlardan başlayarak arama yapan model, bu aramayı kare formda alanlarda gerçekleştirmektedir. Normal çalışmada önemli bölgeler 32, 64, 128, 256 ve 512 piksel kenar boyutundaki kare şeklindeki kutular ile taranmaktadır. Yapılan iyileştirme ile 4, 8, 16, 32 ve 64 piksel kenar boyutlarında ve 0.5, 1, 2 çarpanlarla karşılıklı kenarları farklılaştırılmış dikdörtgen kutular ile yapılmaktadır. Bu sayede MS lezyonların tespitinde başarımın arttığı görülmüştür (Yıldırım & Dandıl, 2020: 13). Şekil 4.17(a)'da standart RoI işlemi, Şekil 4.17(b,c,d)'de geliştirilmiş RoI tespit yapısının lezyon arama davranışlarına örnekler görülmektedir.




(a)



(b)



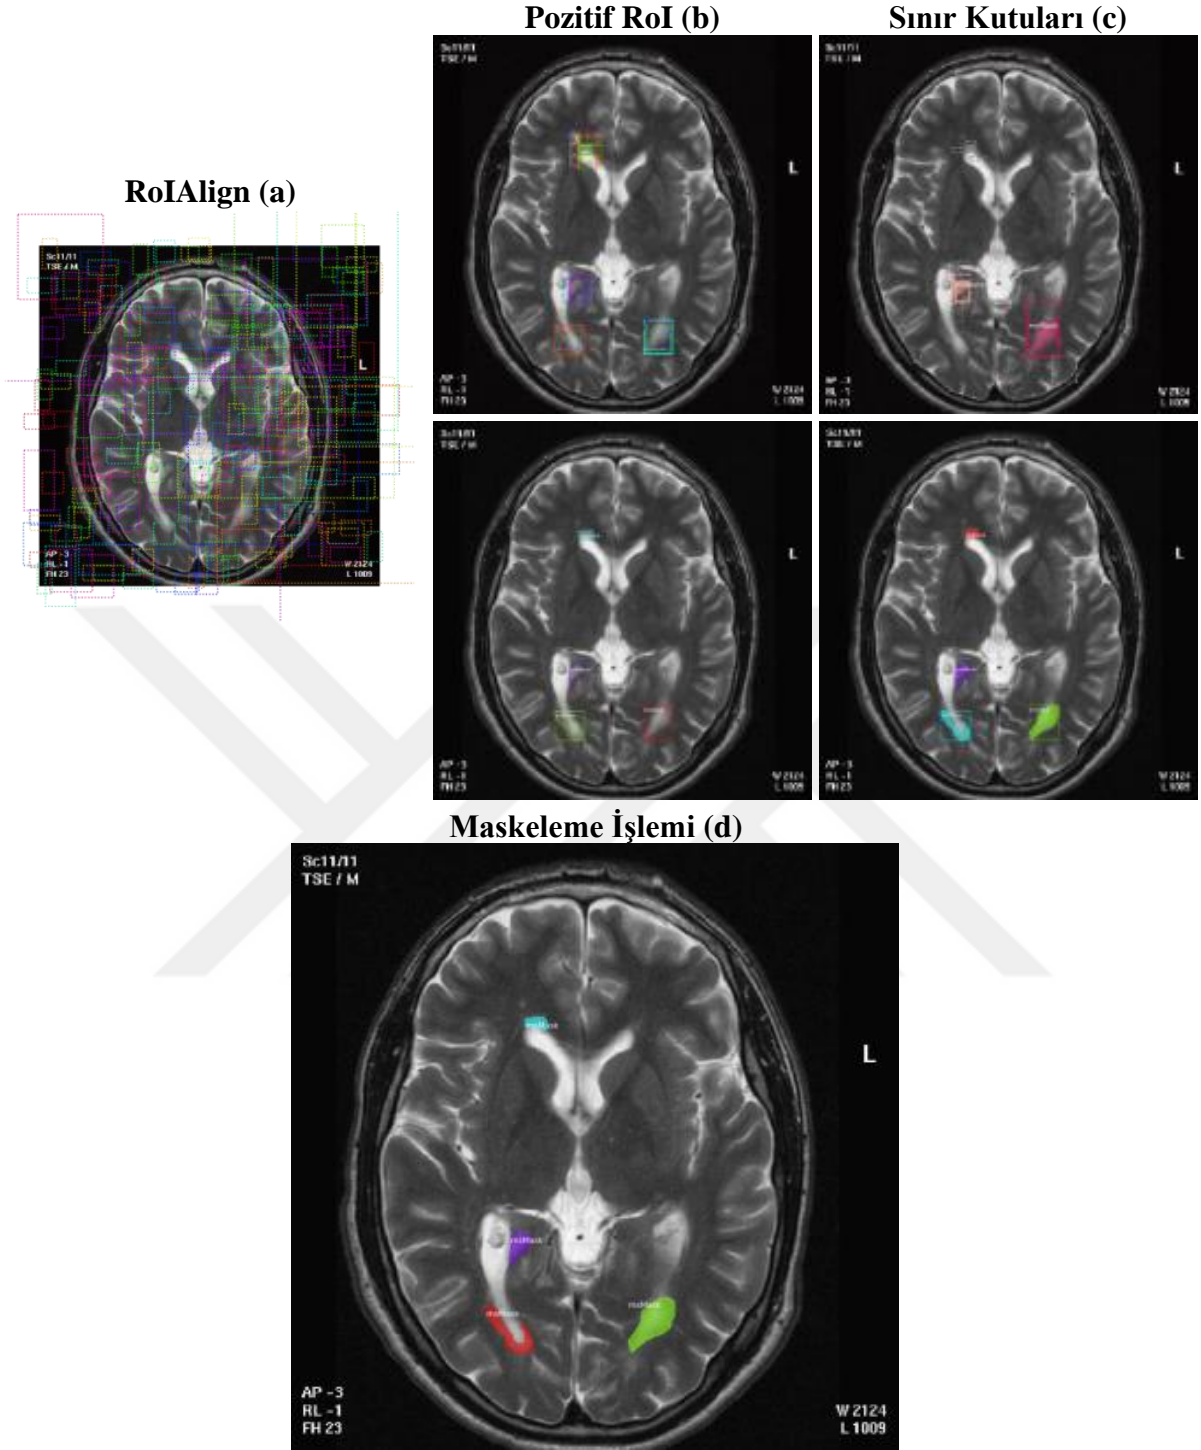
(c)



(d)

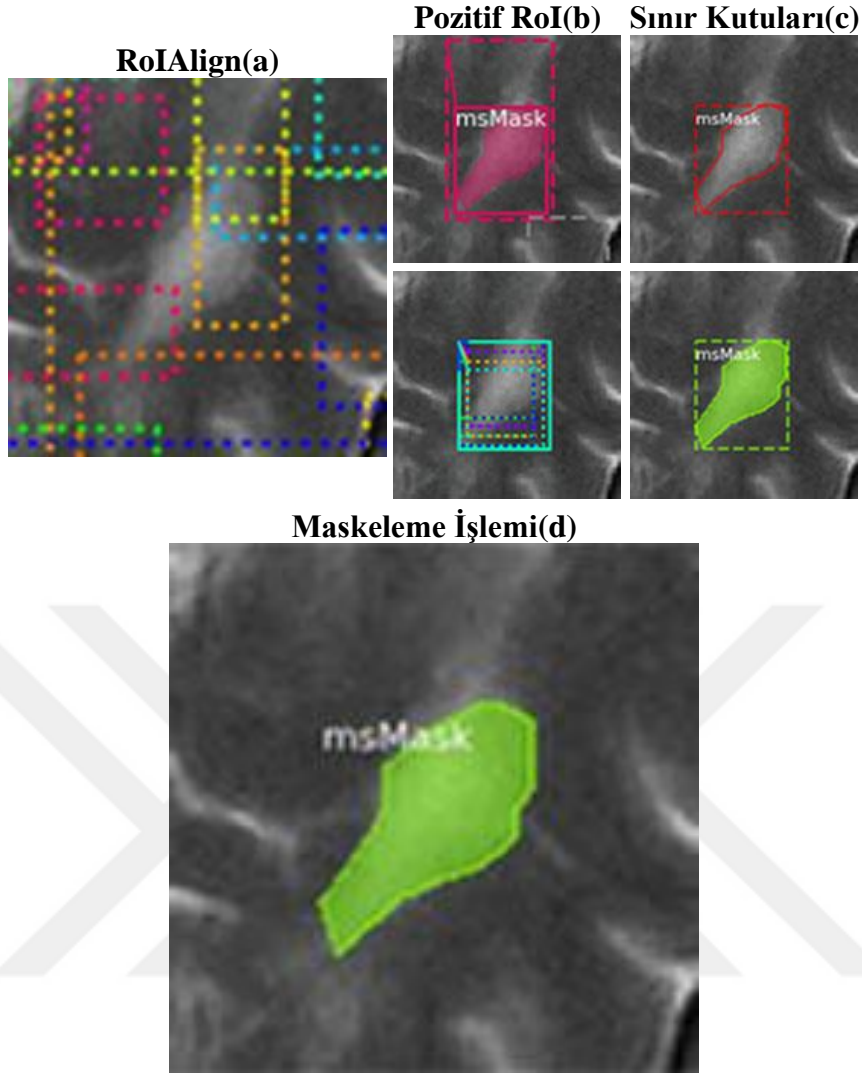
**Şekil 4.17.** (a) Standart RoI Tespit Yapısı, (b, c, d) İyileştirilmiş RoI Tespit Yapısı

Tez çalışması kapsamında geliştirilen iMask R-CNN ile MR görüntüleri üzerinde MS lezyonlarının bölütlemesi (tespiti) işlemi ve uygulanması Şekil 4.18’de gösterilmiştir. Burada, MS lezyon tespitinde tüm görüntü üzerinde yapılan maskeleme işlemi adımları görülmektedir. Öncelikle, Şekil 4.18(a)’da giriş görüntüsü üzerinde özellik çıkarımı sonrasında RoIAlign işlemi yapılarak muhtemel önemli bölgeler belirlenmektedir. Ardından, Şekil 4.18(b)’de bölgeler içinden pozitif olanlar seçilmektedir. Şekil 4.18(c)’de sonraki aşamada segmentasyon için aranan MS lezyonlarını barındıran bölgelerin sınırları belirlenmektedir. Son aşama olan Şekil 4.18(d)’de ise bölgenin sınırları belirlenmektedir ve bölütleme işlemi tamamlanmaktadır.



**Şekil 4.18.** MS Lezyon Tespitinde Tüm Görüntü Üzerinde Yapılan Maskeleme İşlemi Adımları

Şekil 4.19’da MS lezyon tespitinde bir lezyonun tespiti için yapılan işlem süreci detaylı olarak gösterilmiştir. Bir lezyonun belirlenmesi sürecinde de sırasıyla Şekil 4.19(a)’da önemli bölgelerin hizalanması işlemi, Şekil 4.19(b)’de pozitif RoI’lerin belirlenmesi, Şekil 4.19(c)’de sınır alanlarının belirlenmesi ve son aşamada Şekil 4.19(d)’de lezyon alanlarının maskelerinin oluşturulması adımları görülmektedir.



**Şekil 4.19.** MS Lezyon Tespitinde Bir Lezyonun Tespiti İçin Yapılan İşlem Süreci

#### **4.2. Deneysel Sonuçlar**

Bu bölümde tez çalışmaları kapsamında derin öğrenme yöntemleri MS lezyonlarının tespiti için yapılan deneysel çalışmalarda elde edilen sonuçlar sunulmuştur. Deneysel çalışmalarda MR görüntüleri üzerinde MS lezyonlarının tespiti için Mask R-CNN, iMask R-CNN, U-Net derin öğrenme modelleri ile eğitim ve testler gerçekleştirilmiştir. Tez çalışması kapsamında, MS lezyonlarının tespit başarımını karşılaştırmak için birçok deneysel çalışma yapılmış ve elde edilen sonuçlar ile bulgular analiz edilmiştir. Ayrıca iMask R-CNN modeli, ResNet101 ve ResNeXt101 omurga yapıları ile kullanılarak iki farklı mimari oluşturulmuştur. Bunun yanında, Keras ve Detectron2 ortamlarında yapılan deneysel çalışmalar ile farklı ortamların kullanımının MS lezyonlarının tespitine başarımları da değerlendirilmiştir.

Tez çalışması kapsamında önerilen iMask R-CNN modeli üzerinde yapılan tüm deneysel çalışmalar Python programlama dili ile Linux ortamında oluşturulan uygulamalar

aracılığıyla gerçekleştirilmiştir. Bu deneysel analizler için özellikleri Tablo 4.1’de sunulan İş İstasyonu bilgisayar kullanılmıştır ve bilgisayarın konfigürasyon özellikleri sunulmuştur. Bu tabloda görülen işlemci çekirdek sayısı, ekran kartı bellek kapasitesi çalışmanın verimliğinde ve kullanılan görsel miktarda belirleyicidir.

**Tablo 4.1.** Deneysel Çalışmalar İçin Kullanılan Bilgisayarın Konfigürasyon Özellikleri

Donanım	Özellik
Bilgisayar	İş İstasyonu
Merkezi İşlemci (CPU)	Intel Core i9-9900K @ 5 Ghz (8 Core / 16 Thread)
Bellek (RAM)	32 GB (DDR4 2666 Mhz)
Anakart	ASUS WS Z390 PRO
GPU	NVIDIA GeForce RTX 2080Ti 11 GB GDDR6
Harddisk	256 GB SSD HDD + 3 TB SATA 6Gb 3.5’’ HDD

### 4.3. Verisetlerinin Organizasyonu

Tez çalışması kapsamında, MS lezyonlarının derin öğrenme modelleri ile tespiti için deneysel çalışmaların yürütülmesi için MSAkdeniz, UMCL, ISBI2015, eHealth ve MICCAI2008 olmak üzere toplamda beş farklı veriseti kullanılmıştır.

MSAkdeniz verisetinde, MR cihazlarından alınan DICOM formatında görüntüler öncelikle NifTI formatına dönüştürülmüştür. NifTI formatındaki MR çekimlerinin koronal düzleminde, uzman hekimler tarafından MS lezyon alanlarının işaretlenmesi yapılmıştır. Belirlenen lezyon alanlarını içeren bilgiler de NifTI formatında kaydedilmiştir. Koronal kesitler içerisinde MS lezyonu barındıran kesitler Python ortamında hazırlanan yazılım ile otomatik olarak görüntüye dönüştürülmüştür. MR görüntülerinin çözünürlüğü 512x512 piksel boyutlarındadır. Bu verisetinde, tez kapsamında yapılan çalışmalar için seçilen kesitler içinden rastgele eğitim ve test kümeleri ayrılmıştır. Verisetinde, lezyon barındıran kesitlerden 400 eğitim (%75) ve 130 test (%25) olmak üzere toplamda rastgele 530 görüntü seçilmiştir.

eHealth verisetinde, MR kesitleri görüntü olarak ve uzman hekimler tarafından hazırlanan MS lezyon seçimlerini içerecek şekilde .plq formatında sunulmuştur. Verisetinde MR görüntülerinde farklı formatlar bulunduğundan, bu görüntülerin tamamı .JPG görüntü formatına çevrilmiştir. Verisetindeki MR görüntülerinin çözünürlüğü 512x512 piksel ve 378x378 piksel boyutlarında değişmektedir. Ayrıca, .plq formatındaki görüntülerin koordinat bilgileri VGG 1.6 JSON formatında kaydedilmiştir. Tez kapsamında, bu verisetinden lezyon

barındıran görüntüler içinden 398 eğitim (%77) ve 121 test (%23) görüntüsü rastgele seçilerek deneysel çalışmalarda kullanılmıştır.

UMCL veriseti de NifTI formatlı MR görüntülerinden oluşturulmuş açık bir verisetidir. Verisetindeki görüntüler 3 düzleme de uygun hale getirmek için eksenler keşiştirildiğinden, görüntülerin kalitesinde birtakım kayıplar oluşmuştur. Ancak, uzman görüşlerini içeren maskeler 3B olarak görüntülerle birleştirilerek sunulmuştur. Verisetindeki MR taramalarının çözünürlüğü 512x512 boyutlarındadır. Tez çalışması kapsamında, uzman görüşlerini içeren maskeler ve aksiyel açıdan MR görüntüleri Python ortamında kesit-kesit çıkarılmıştır. Bu kesitler arasından rasgele seçilen görüntüler kullanılarak eğitim ve testler gerçekleştirilmiştir. Tez kapsamında yapılan deneysel çalışmalarda, bu verisetinden lezyon barındıran 500 eğitim (%83) 100 test (%17) olmak üzere toplamda 600 kesit eğitim setinden rastgele seçilmiştir.

ISBI veriseti ön-işlemden geçirilerek beyin bölgesi ayrılmış NifTI formatlı MR görüntülerinden oluşturulmuş bir verisetidir. MR çekimlerinin çözünürlüğü 181x217 boyutlarındadır. Deneysel çalışmalar için MR çekimleri içinde sunulan maskelerden lezyon içeren aksiyel kesitler çıkarılmıştır. Bu kesitler arasından rasgele eğitim için MS lezyonu barındıran 500(%83) kesit, test için ise 100 (%17) kesit alınmıştır.

MICCAI2008 veriseti NifTI formatlı MR görüntülerinden oluşturulmuş bir verisetidir. Verisetindeki MR çekimlerinin çözünürlüğü 512x512 boyutlarındadır. Deneysel çalışmalar için MR çekimleri içinde sunulan maskelerde lezyon içeren aksiyel kesitler çıkarılmıştır. Bu kesitlerden eğitim için MS lezyonu barındıran 434 (%77) kesit, test için 131(%23) kesit belirlenmiştir.

Çalışmada kullanılan MSAkdeniz, UMCL, ISBI ve MICCAI2008 verisetlerinde uzman görüşleri görüntü olarak alınarak görüntü üzerinde yapılan işlemler ile dolu alanların koordinatları tespit edilmiştir. Koordinatlar VGG 1.6 JSON formatında kaydedilmiştir.

#### **4.4. Performans Ölçüm Metrikleri**

Tez çalışması kapsamında, MS lezyonlarının tespiti için önerilen derin öğrenme modellerinde yapılan deneysel çalışmaların başarımını tespit etmek için literatürde sıkça kullanılan ölçüm metrikleri kullanılmıştır. Tez kapsamında yapılan çalışmalarda tüm ölçümler görüntüler üzerinden tek tek alınmıştır ve tur (epok, epoch) sonuçları ortalama olarak sunulmuştur. Metrikler ile görüntüler üzerinde bölütleme ve lezyon bazlı olmak üzere iki çeşit ölçüm yapılabilmektedir.

Bölütleme bazı ölçümde, “*İncelenen derin öğrenme modeli lezyon alanlarını hangi oranda doğrulukta bulabiliyor?*” sorusunun cevabını aramaktadır. Dice benzerlik katsayısı (Dice Similarity Coefficient, DSC), Jaccard benzerlik katsayısı (Jaccard Coefficient Similarity, JSC), alan yoğunluk farkı (Volumetric Overlap Error, VOE), ortalama simetrik yüzey mesafesi (Average Symmetric Surface Distance, ASD), göreceli hacim farkı (Relative Volume Difference, RVD) ve hausdorff mesafesi (Hausdorff Distance 95, HD95) metrikleri ile bu açıdan değerlendirme yapılabilmektedir.

Lezyon bazlı ölçümlerde ise, “*Önerilen derin öğrenme modeli lezyon alanlarından bağımsız olarak MR görüntüsü üzerindeki tüm lezyonları tespit edebiliyor mu?*” sorusu incelenmektedir. Lezyon doğru tespit oranı (Lession True Positive Rate, LTPR), lezyon yanlış tespit oranı (Lession False Positive Rate, LFPR), Kesinlik (Precision, PRE), Duyarlılık (Recall, RC) metrikler ile lezyon bazlı ölçümler yapılmaktadır.

Performans metriklerinin detayları açıklanırken  $A_{gt}$  görüntü üzerinde uzman tarafından lezyon olan tanımlanmış alanını,  $A_{seg}$  görüntü üzerinde önerilen model ile belirlenmiş seçim alanını (bölütleme sonucunu) göstermektedir. Ayrıca, Tablo 4.2’de detayları görülen karmaşıklık matrisindeki doğru pozitif (True Positive, TP), yanlış pozitif (False Positive, FP), doğru negatif (True Negative, TN) ve yanlış negatif (False Negative, FN) değerleri ölçüm metriklerinin tanımlanmasında kullanılmaktadır.

**Tablo 4.2.** Performans Ölçütlerinin Hesaplanmasında Kullanılan Karmaşıklık Matrisi

		Tahmin Edilen (Predicted)	
		Doğru Pozitif (True Positive, TP)	Yanlış Negatif (False Negative, FN)
Gerçek (Uzman Görüşü)	Doğru Pozitif (True Positive, TP)	Doğru Pozitif (True Positive, TP)	Yanlış Negatif (False Negative, FN)
	Yanlış Pozitif (False Positive, FP)	Yanlış Pozitif (False Positive, FP)	Doğru Negatif (True Negative, TN)

Kullanılan ölçütlerden Eşitlik (4.1)’de gösterilen DSC (Zou vd., 2004: 181) ve Eşitlik (4.2)’de görülen JSC (Jaccard, 1912: 37) uzman hekim tarafından seçilen alan ile tahmin edilen ölçüm sonucu yerleşen alanın örtüşme oranına göre hesaplanan ölçütlerdir. Ayrıca bu iki ölçüt arasındaki matematiksel ilişki Eşitlik (4.3) ve Eşitlik (4.4)’te görüldüğü gibidir. Bu metriklerin benzer ölçümler yaptığı ve modeller tarafından seçilen lezyonları alan bazında nasıl ölçtükları görülmektedir(Taha & Hanbury, 2015: 5).

$$DSC = \frac{2|A_{gt} \cap A_{seg}|}{|A_{gt}| \cup |A_{seg}|} = \frac{2TP}{2TP + FP + FN} \quad (4.1)$$

$$JSC = \frac{|A_{gt} \cap A_{seg}|}{|A_{gt} \cup A_{seg}|} = \frac{TP}{TP + FP + FN} \quad (4.2)$$

$$JSC = \frac{DSC}{2 - DSC} \quad (4.3)$$

$$DSC = \frac{2JSC}{1 + JSC} \quad (4.4)$$

Ölçüm hatalarını belirlemek için kullanılan yoğunluk oran hatasının (VOE) hesaplandığı formül Eşitlik (4.5)'de görülmektedir (Ruskó vd., 2009: 879). VOE model tarafından belirlenen alan ile uzman tarafından önceden belirlenmiş alan arasındaki hacimsel farka dayanmaktadır. Ortalama simetrik yüzey mesafesi (ASD) hesaplanırken her noktanın arasındaki mesafe öklid mesafesi ile ölçülerek bunların toplamalarının genel tespiti oranı karşılaştırılır. Bu sayede segmentasyon başarımı farklı açıdan yapılabilmektedir (Kavur vd., 2020: 15). Noktaların öklid mesafesini ölçen formül Eşitlik (4.6)'da ASD'nin formülü Eşitlik (4.7)'de görülmektedir. Eşitlik (4.8)'de görülen göreceli hacim farkı (RVD) seçilen alan ile referans alan arasındaki farkı mutlak boyut olarak ölçmektedir(Ahn vd., 2019: 6).

$$VOE = 1 - \frac{|A_{gt} \cap A_{seg}|}{|A_{gt} \cup A_{seg}|} = 1 - \frac{TP}{TP + FP + FN} = 1 - JSC \quad (4.5)$$

$$d(x, A) = \min_{y \in A} (d(x, y)) \quad (4.6)$$

$$ASD = \frac{1}{|A_{gt}| + |A_{seg}|} \times \left( \sum_{x \in A_{seg}} d(x, A_{gt}) + \sum_{y \in A_{gt}} d(y, A_{seg}) \right) \quad (4.7)$$

$$RVD = \frac{|A_{ref}| - |A_{gt}|}{|A_{gt}|} \quad (4.8)$$

Hausdorff mesafesinin ölçümü için gerekli olan sınırlar arasındaki mesafelerin ölçüm formülü Eşitlik (4.9)'da, HD'nin formülü ise Eşitlik (4.10)'da görülmektedir. HD bölütlenen alan ile referans arasındaki mesafeler arasında en büyük olanın alınması olarak tanımlanır. HD95 ise bu işlem yapılırken %5 hatanın görmezden gelinerek hesaplanmasıdır (Karimi &

Salcudean, 2019: 499). HD95 ile medikal görüntülerde oluşan gürültülerin ölçümleri etkilemesinin önüne geçildiği görülmüştür. HD95’de hata ölçüm sonuçları 0(sıfır)’a yaklaştıkça başarımlar artmaktadır.

$$\text{hd}(A_{\text{ref}}, A_{\text{gt}}) = \max_{x \in A_{\text{ref}}} \min_{y \in A_{\text{gt}}} \|x - y\|_2 \quad (4.9)$$

$$\text{hd}(A_{\text{gt}}, A_{\text{ref}}) = \max_{y \in A_{\text{gt}}} \min_{x \in A_{\text{ref}}} \|x - y\|_2$$

$$\text{HD}(X, Y) = \max(\text{hd}(A_{\text{ref}}, A_{\text{gt}}), \text{hd}(A_{\text{gt}}, A_{\text{ref}})) \quad (4.10)$$

Lezyon doğru tespit oranı (LTPR) Eşitlik (4.11)’de görülmektedir. LTPR doğru seçilen lezyon bölgelerinin MR kesiti üzerindeki toplam lezyon adedine oranını gösterir (Brosch vd., 2016: 1234; Gessert, Bengs, vd., 2020: 4; Hashemi vd., 2018: 1728) Bu sayede MR kesitinde bulunan lezyonlardan ne kadarının doğru tespit edildiği belirlenir (Hashemi vd., 2018: 1728). Lezyon yanlış tespit oranı ise (LFPR) Eşitlik (4.12)’de görülmektedir. LFPR derin öğrenme modeli işlemleri sonucunda lezyon olmayan ama lezyon olarak belirlenmiş alanların, toplam tespit sayısına oranı olarak ifade edilir (Brosch vd., 2016: 1234; Gessert, Bengs, vd., 2020: 4; Hashemi vd., 2018: 1728). Bu sayede belirlenen lezyonların hangi oranda hatalı olduğu belirlenmektedir. Lezyon tespiti üzerinden ölçüm yapan metriklerin gösteriminde  $S_{\text{LTP}}$  doğru tespit edilen lezyon sayısını,  $S_{\text{LS}}$  MR kesiti üzerinde bulunan referans lezyon sayısını,  $S_{\text{LFP}}$  segmentasyon sonucu lezyon olarak belirlenmiş ancak yanlış tespit edilen lezyon sayısını,  $S_{\text{PS}}$  segmentasyon sonucunda tespit edilen toplam lezyon sayısını göstermektedir.

$$\text{LTPR} = \frac{S_{\text{LTP}}}{S_{\text{LS}}} \quad (4.11)$$

$$\text{LFPR} = \frac{S_{\text{LFP}}}{S_{\text{PS}}} \quad (4.12)$$

Kesinlik (Precision, PRE) ve duyarlılık (Recall RC) metrikleri birçok alanda kullanıldığı gibi görüntü işleme alanında da kullanılan önemli ölçüm metrikleridir. Ayrıca başka isimlerle anılan ve sık kullanılan metrikler ile eşitlik ya da benzerlikleri bulunmaktadır. Eşitlik (4.13)’de kesinlik (PRE)’nin, Eşitlik (4.14)’de duyarlılığın (RC) denklemleri görülmektedir. Kesinlik aynı zamanda lezyon tabanlı inceleme yapan çalışmalarda doğru

tahmin değeri (Positive Predictive Value, PPV) ile eşittir. Duyarlılık ise doğru pozitif oranı (True Pozitive Rate, TPR) ile eşittir.

$$PRE = \frac{TP}{TP + FP} = PPV \quad (4.13)$$

$$RC = \frac{TP}{TP + FN} = TPR \quad (4.14)$$

#### 4.5. Derin Öğrenme Modellerinin Organizasyonu

Tez çalışması kapsamında, MS lezyonlarının tespiti için önerilen Mask R-CNN ve iMask R-CNN modelleri ile yürütülen deneysel çalışmalarda Keras ortamında kullanılan spesifik ayarlar Tablo 4.3'te verilmiştir. Bu ayarlar belirlenirken ağ çeşitli aşamalardan geçirilmiş ve en uygun model oluşturulmuştur. Çift GPU ile yapılan deneysel çalışmalar için en uygun iterasyon sayısının 1000, tur sayısının ise 100 olduğu testlerin sonucu ile doğrulanmıştır. Modellerin test aşamasında, performans ölçümlerin sağlıklı yapılabilmesi için eğitim sürecindeki her turda elde edilen ağırlıkları ayrı ayrı hesaba tabi tutan bir yapı hazırlanmıştır. Her tur için elde edilen ağırlıklar kullanılarak test işlemi tekrar tekrar yapılarak sistemin test başarımları doğrulanmıştır.

**Tablo 4.3.** Mask R-CNN ve iMask R-CNN Mimarileri İçin Belirlenen Spesifik Ayarlar

Ayar	Değer	Açıklaması
BACKBONE	ResNet101	Kullanılacak olan ön eğitilmiş ağ modeli.
GPU_COUNT	2	Ağın çalışacağı GPU değeri.
IMAGE_MIN_DIM	256	Verisetindeki görüntülerin minimum kenar uzunluğu
IMAGE_MAX_DIM	512	Verisetindeki görüntülerin maksimum kenar uzunluğu
TRAIN_ROIS_PER_IMAGE	200	Eğitimde her resim için çıkartılacak tahmini bölgelerin adedi
MAX_GT_INSTANCES	100	Bir görüntüde bulunacak en fazla lezyon sayısı
IMAGES_PER_GPU	2	GPU başına düşen görüntü sayısı
NUM_CLASSES	1+1	Lezyonlar üzerindeki sınıf sayısı (1 msLezyon + 1 arkaplan)
STEPS_PER_EPOCH	1000	Her turdaki tekrar sayısı
EPOCH_COUNT	50	Tur sayısı
THRESHOLD	0.2	Bir lezyonun tespit başarımı için belirlenen maksimum hata oranı

Detectron2 üzerinde iyileştirilmiş Mask R-CNN modeli (iMask R-CNN) ile ResNet101 ve ResNeXt101 omurga yapıları kullanılarak farklı veriseti üzerinde eğitimler ve testler gerçekleştirilmiştir. Detectron2 yapısı üzerinde belirlenen spesifik ayarlar ise Tablo 4.4'te verilmiştir. Bu ayarlar belirlenirken yine ağ çeşitli aşamalardan geçirilerek en uygun model elde edilmiştir. Aynı zamanda, yine önerilen modelin test aşamasında, performans ölçümlerin sağlıklı yapılabilmesi için eğitim sürecindeki belirlenen periyotlarda elde edilen ağırlıkları ayrı ayrı hesaba tabi tutan bir yapı hazırlanmıştır. Böylece, her periyod için elde edilen ağırlıklar kullanılarak test işlemi tekrar tekrar uygulanmış ve önerilen modelin test başarımları doğrulanmıştır.

U-Net modeli için Tensorflow2 ve Keras platformunda optimize edici olarak ADAM fonksiyonu, hata fonksiyonu olarak MSE, metrik olarak MeanIOU kullanılmıştır. U-Net derin öğrenme modeli ile 100 tur eğitim yapılmıştır. Eğitim turu sonucunda onaylama oranı %20 olarak ayarlanmış ve eğitim verisinin %20 'si en başta onaylama için ayrılmıştır.

**Tablo 4.4.** Detectron 2 ile Mask R-CNN Modelinin Uygulanması İçin Belirlenen Spesifik Ayarlar

Ayar	Değer	Açıklaması
BACKBONE	ResNet101 / ResNeXt101	Kullanılacak olan omurga yapısı.
IMS_PER_BATCH	2	Eğitim sırasında her GPU'ya gönderilecek görüntü sayısı.
BASE_LR	0.001	Öğrenme katsayısı.
BATCH_SIZE_PER_IMAGE	256	Bir görüntü üzerinde aranacak önemli bölge sayısı
NUM_CLASSES	1	Aranacak sınıf sayısı (msMask)
CHECHPOINT_PERIOD	1000	Ağırlıkların kaydedileceği iterasyon periyodu
MAX_ITER	100000	Eğitimin süreceği toplam iterasyon sayısı
THRESHOLD	0.2	Bir lezyonun tespit başarımı için belirlenen minimum örtüşme oranı

Tez çalışması kapsamında kullanılan modellerin, derin öğrenme platformlarının ve omurga yapılarının kolay ifade edilebilmesi için Tablo 4.5'teki kısa isimlendirme kullanılmıştır. Bu kısa isimlendirmeler ilk başta kullanılan model, ikinci sırada kullanılan omurga ve son sırada kullanılan platform eklenerek oluşturulmuştur.

**Tablo 4.5.** Tez Kapsamında Kullanılan Derin Öğrenme Modellerinin Kısa İsimleri

Kısa İsim	Platform		Omurga Yapısı	
	TensorFlow2 ve Keras	PyTorch ve Detectron2	ResNet 101	ResNeXt 101
U-Net	X			
Mask R-CNN-R101-K	X		X	
iMask R-CNN-R101-K	X		X	
iMask R-CNN-R101-D		X	X	
iMask R-CNN-RX101-D		X		X


#### 4.6. MSAkdeniz Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar

Tez çalışması kapsamında hazırlanan özgün veriseti üzerinde U-Net, Mask R-CNN-R101-K, iMask R-CNN-R101-K, iMask R-CNN-R101-D, iMask R-CNN-RX101-D derin öğrenme modellerinde eğitim ve testler gerçekleştirilmiştir. Bu bölümde MSAkdeniz veriseti ile yapılan tüm eğitim ve test süreçlerinin detaylarını ve başarılı MR görüntüleri sunulmuştur.

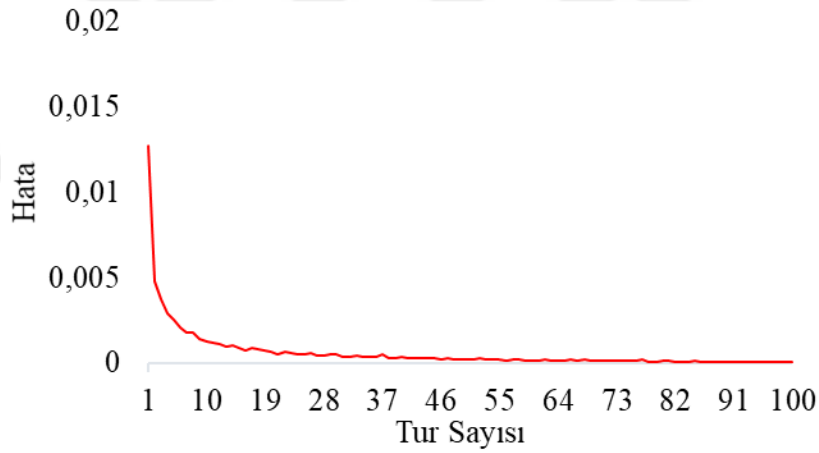
##### 4.6.1. MSAkdeniz Verisetinde U-Net ile Elde Edilen Sonuçlar

MSAkdeniz veriseti üzerinde U-Net ile yapılan eğitimlerde veri arttırma katsayısı 4, ölçüm aralık çarpanı 1 olarak belirlenmiştir. Bu oranlar kullanılarak 400 eğitim ve 130 test görüntüsünden oluşan veriseti, veri arttırma işlemi uygulandıktan sonra 3202 eğitim ve 1042 test verisi çıkarılmıştır. Her görüntüden ortalama 8 farklı versiyon üretilmiştir. Şekil 4.20’de MSAkdeniz verisetinde veri arttırma işlemi uygulanarak elde edilmiş MR görüntüleri ve aynı görüntülerin uzman görüşlerinin (maskelerinin, groudth truth) veri arttırma işlemi uygulanmış halleri gösterilmiştir.

MSAkdeniz verisetinde, veri arttırımı yapıldıktan sonra 100 tur eğitim gerçekleştirilmiş ve her turda ağırlıklar kaydedilmiştir. Eğitimin tamamlanmasından sonra, test verileri kullanılarak bu ağırlıklar üzerinden sonuçlar hesaplanmıştır. Grafik 4.1’de MSAkdeniz verisetinin U-Net ile eğitimi sürecinde hata değişim grafiği görülmektedir. Burada eğitim sürecinde gerçekleşen hata oranındaki değişim izlenmektedir. Hata değişimi 0.015’den başlamasının nedeni veri arttırımı sırasında U-Net modelinin eğitim sürecinin başlamış olmasıdır. Ayrıca hata değişiminin sıfıra eğitim sürecinin ortalarında yaklaştığı açıkça görülmektedir.

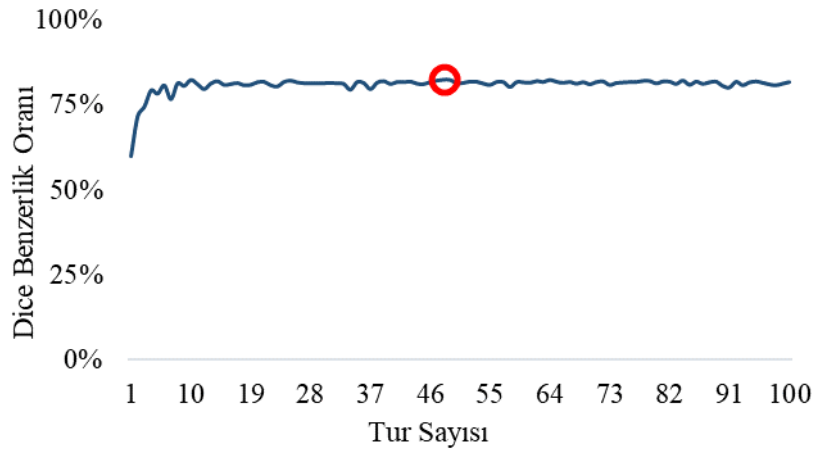


**Şekil 4.20.** MSAkdeniz Verisetinde MR Görüntüleri ve Uzmanlar Tarafından Belirlenmiş Lezyon Maskelerinin Veri Arttırma Sonucu Üretilen Versiyonları



**Grafik 4.1.** MSAkdeniz Verisetinde U-Net ile Eğitim Sürecinde Hata Değişim Grafiği

MSAkdeniz verisetinde U-Net ile eğitim ve test çalışmaları başarıyla tamamlanmıştır. Grafik 4.2’de yapılan eğitimler sonucunda elde edilen ağırlıkların test veriseti üzerindeki DSC’nin değişimi görülmektedir. Ayrıca grafik üzerinde en iyi tur sonucu işaretlenmiştir. Bu grafik incelendiğinde, test sonuçlarının ilk turlardan itibaren kararlı olduğu görüldüğü için test sonuçlarının DSC bakımından ilk turlardan itibaren yakın başarıma sahip olduğu anlaşılmaktadır.




**Grafik 4.2.** MS Akdeniz Verisetinde U-Net ile Yapılan Testlerinin DSC Değişimi

MS Akdeniz veriseti üzerinde U-Net eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen ölçüm metrik skorları Tablo 4.6’da görülmektedir. Bu tablo incelendiğinde, DSC skorunun %82.55, LTPR oranının %92.01 ile lezyonlarının çoğunluğunun model tarafından otomatik olarak bölümlendiği görülmektedir. Bu sonuçlara göre U-Net modeli ile otomatik lezyon tespiti önemli bir başarıyla sağlanmıştır.

**Tablo 4.6.** MS Akdeniz Verisetinin U-Net ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%82.55	%71.56	%28.43	%92.01	%12.76	%85.98	%81.16	0.1679	15.8079	3.5675


Yapılan testlerde U-Net ile MS Akdeniz veriseti üzerinde MS lezyonlarının tespitinin başarılı bir şekilde gerçekleştirildiği görülmüştür. Şekil 4.21’de her görüntünün üstünde sırasıyla (a) orijinal MR görüntüsü, (b) uzman hekimlerin belirlediği lezyon alanları, (c) U-Net modelinin belirlediği lezyon alanları üstte verilmiş, bu görüntülerin altında (d) orijinal MR ve uzman görüşü (sarı renkli alanlar) ile sistem tahmini (kırmızı renkli alanlar) sonuçlarının örtüşmesi verilmiştir. Şekilde 4 farklı MR kesitinin sonuçları aynı sıralama ile gösterilmiştir.



**Şekil 4.21.** MSAkdeniz Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi


#### 4.6.2. MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar

MSAkdeniz verisetinin Mask R-CNN-R101-K modeli kullanarak yapılan eğitim sürecinin grafiği Grafik 4.3'te görülmektedir. Grafikte görülen maskeleme hatası, eğitim sürecinde maskelemek için belirlenen bölgenin doğruluğunu ve sınıf hatası, maskelemek için belirlenen bölgenin sistem üzerinden doğru sınıf tanımlanmasını ifade eder. Genel hata ile eğitim sürecinde maskeleme hatası, sınıf hatası, doğru bölge belirleme hatası, belirlenen bölgenin içerisinde maske alanının doğru belirlenmesi hatalarının toplamı ifade edilmektedir. Bu hata ölçümlerinde tüm çeşitler kendi içinde 1'den 0'a azalmaktadır. Genel hata ile bu hataların toplamı ifade edildiği için belli birim kullanılmamıştır. Hata verileri eğitim sürecinde 100 tur için ayrı ayrı kaydedilmiştir. Grafik incelendiğinde, eğitim sürecinde genel hatanın hızla değişimi görülmektedir. Eğitim sürecinin başından itibaren sınıf hatasının sıfıra yakın olmasının nedeni sadece "msMask" isimli lezyon sınıfının aranmasıdır.



**Grafik 4.3.** MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Yapılan Eğitim Sürecindeki Hata Değişim Grafiği

MSAkdeniz verisetinde Mask R-CNN-R101-K ile yapılan eğitim 100 tur tekrarlanmış ve her turda bir ağırlıklar kaydedilmiştir. Bu ağırlıklar ile test kümesi üzerinde yapılan analizlerde DSC'nin değişimi Grafik 4.4'te görüldüğü gibidir. Burada dikkati çeken test verileri üzerinde yapılan incelemenin DSC bakımından eğitim sürecinin ortalarında en başarılı noktaya ulaşmasıdır. Ayrıca grafik üzerindeki titreşimlerin nedeni Mask R-CNN-R101-K ile maske sınırlarının doğru tespitinde ilk turlarda zorluk yaşamasıdır.



**Grafik 4.4.** MSAkdeniz Veriseti ile Mask R-CNN-R101-K Üzerinde Yapılan Testlerin DSC Değişimi


MSAkdeniz verisetinde, Mask R-CNN-R101-K eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen ölçüm metriklerinin skorları Tablo 4.7’de verilmiştir. DSC ve LTPR metriklerine göre; %83.64 ve %84.58 oranlarına ulaşılmıştır. Bu değerlere göre lezyon alanlarının tespiti önemli oranda sağlanmıştır. Tablonun geneli incelendiğinde, deneysel çalışmalarda Mask R-CNN-R101-K ile MSAkdeniz veriseti üzerinde başarımlı sağlandığı görülmüştür.

**Tablo 4.7.** MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Elde Edilen En İyi Tur Sonuçları






DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%83.64	%75.98	%24.01	%84.58	%12.79	%87.34	%84.03	0.2908	23.2923	4.2312

Şekil 4.22’de MSAkdeniz veriseti üzerinde Mask R-CNN-R101-K ile yapılan testlerdeki en iyi turdan alınan MR görüntülerinden bazıları görülmektedir. Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. Burada lezyon olarak belirlenen alanlar ile uzman görüşleri arasındaki başarılı örtüşme göze çarpmaktadır.

(a) Uzman Seçimi (Ground Truth)




(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.22. MSAkdeniz Verisetinde Mask R-CNN-R101-K ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri


### 4.6.3. MSAkdeniz Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonular

MSAkdeniz verisetinin iMask R-CNN-R101-K modeli ile yapılan eđitim srecinin hata deđişimleri Grafik 4.5'te grlmektedir. Bu grafik incelendiđinde genel hatanın 1.5'den bařladıđı, eđitim srecinin bařlarından itibaren hızla azaldıđı ve eđitim srecinin ortalarında maskeleme hatasına eřitlendiđi grlmektedir.



**Grafik 4.5.** MSAkdeniz Verisetinde iMask R-CNN-R101-K ile Yapılan Eđitim Srecindeki Hataların Deđişim Grafiđi

MSAkdeniz verisetinde, Mask R-CNN-R101-K ile yapılan eđitim 100 tur tekrarlanmış ve her turda bir ađırlıklar kaydedilmiřtir. Bu ađırlıklar ile test kmesi zerinde yapılan analizlerde DSC'nin deđiřimi Grafik 4.6'da grldđi gibi. Bu grafik incelendiđinde; eđitim srecinin ilk turlarında alınan ađırlıklar ile test verisetinin bařarımının rtřmemesinden kaynaklı bir titreřim olduđu grlmektedir. Hata grafiđinde olduđu gibi orta noktadan sonra grafiđin daha kararlı bir řekilde ykseldiđi ve eđitim srecindeki bařarımın test veriseti iinde sađlandıđı izlenmektedir.



**Grafik 4.6.** MSAkdeniz Veriseti ile Mask R-CNN-R101-K zerinde Yapılan Testlerin DSC Deđiřimi

iMask R-CNN-R101-K eğitimlerinde DSC benzerlik katsayısı bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.8’de verilmiştir. Burada %81.97 DSC, %85.39 LTPR oranı ile etkili bir şekilde lezyon bölütlemesi yapıldığı görülmektedir. Yapılan testlerde iMask R-CNN-R101-K ile MSAkdeniz veriseti üzerinde önemli başarımlar sağlandığı görülmüştür.

**Tablo 4.8.** MSAkdeniz Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları


DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%81.97	%74.12	%25.88	%85.39	%15.13	%83.47	%85.05	0.2571	22.1072	4.6402

Şekil 4.23’de MSAkdeniz veriseti üzerinde iMask R-CNN-R101-K ile yapılan testlerdeki en iyi turdan alınan MR görüntülerinden bazıları görülmektedir. Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. Lezyon olarak belirlenen alanların uzman seçimleri ile başarıyla örtüştüğü açıkça görülmektedir.





#### 4.6.4. MSAkdeniz Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonuçlar

MSAkdeniz verisetinin iMask R-CNN-R101-D ile yapılan eğitim sürecinin hata değişimleri Grafik 4.7’de görülmektedir. Grafikte görülen maskeleme hatası eğitim sürecinde maskelemek için belirlenen bölgenin doğruluğunu ve sınıf hatası maskelemek için belirlenen bölgenin sistem üzerinden doğru sınıf tanımlanmasını ifade etmektedir. Genel hata eğitim sürecinde maskeleme hatası, sınıf hatası, doğru bölge belirleme hatası, belirlenen bölgenin içerisinde maske alanının doğru belirlenmesi hatalarının toplamından oluşmaktadır. Hata verileri her 100 iterasyon da 1 kez olmak üzere toplam 100.000 iterasyon için 1000 adımda ayrı ayrı kaydedilmiştir. Bu nedenle grafikte görülen çizgiler çok sık titreşim içermektedir. Hata değişim grafiği tüm hataların toplamı için 1 değerinden başlaması ve hızla düşüşü eğitim sürecinin başarımlarını göstermektedir. Bu grafik incelendiğinde eğitim sürecinde genel hatanın hızlı ve kararlı bir şekilde düştüğü görülmektedir.


(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi




Şekil 4.23. MSAkdeniz Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri



**Grafik 4.7.** MSAkdeniz Verisetinde iMask R-CNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği

MSAkdeniz verisetinde iMask R-CNN-R101-D ile yapılan eğitim sürecinde her 1000 iterasyonda bir periyot noktası (kontrol noktası / checkpoint) belirlenmiş ve ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC değişim oranı sonuçları Grafik 4.8’de görüldüğü gibidir. Burada eğitim süreci sonucunda elde edilen ağırlıkların test veriseti için tüm kontrol noktaları için yakın başarımda olduğu görülmektedir. Her turda yakın başarımların alınması ayrıca Detectron2 platformunun kararlılığını göstermektedir.



**Grafik 4.8.** MSAkdeniz Verisetinin iMask R-CNN-R101-D Üzerinde Yapılan Testlerin DSC Değişimi

MSAkdeniz Veriseti üzerinde iMask R-CNN-R101-D eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.9’da görülmektedir. Bu tablo incelendiğinde; DSC %83.47 LTPR %90.77 ile lezyonların ve lezyon alanlarının doğru tespit başarımının yüksekliği, LFPR %6.63 ve HD95’in 8.10 değerleri ile hata oranlarındaki düşüklüğü görülmektedir. Yapılan testlerde iMask R-CNN-R101-D ile MSAkdeniz verisetinde MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür.


**Tablo 4.9.** MSAkdeniz Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%83.47	%71.50	%28.49	%90.77	%6.63	%89.47	%89.08	0.1595	8.108911	1.551881

Şekil 4.24’de MSAkdeniz veriseti üzerinde iMask R-CNN-R101-D ile yapılan testlerdeki en iyi turdan alınan MR görüntülerinden bazıları görülmektedir. Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir.

#### 4.6.5. MSAkdeniz Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar


MSAkdeniz verisetinin iMask R-CNN-RX101-D ile yapılan eğitiminin hata değişim grafiği Grafik 4.9’da görülmektedir. Bu grafik incelendiğinde genel hatanın, maskeleye hatasının kararlı düşüşü görülmektedir. Buradaki kararlılık Detectron2 platformunun kullanılması ile sağlanmıştır.








**Grafik 4.9.** MSAkdeniz Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Hata Değişim Grafiği

MSAkdeniz verisetinin iMask R-CNN-RX101-D ile yapılan eğitim sürecinde her 1000 iterasyonda bir kez ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.10'da görülmektedir. Bu grafik incelendiğinde, test süreci boyunca yakın sonuçlar alındığı ve modelin test kümesi üzerindeki kararlı yapısı göze çarpmaktadır. Önerilen modelin test veriseti ile eğitim sürecinde elde edilen tüm ağırlıklar için etkin bir başarımla sağladığı açıkça görülmektedir.


(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.24. MSAkdeniz Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri



**Grafik 4.10.** MSAkdeniz Verisetinde iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların Testlerdeki DSC Değişimi


iMask R-CNN-RX101-D ile MSAkdeniz veriseti üzerinde yapılan eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.10'da görülmektedir. Bu tablo incelendiğinde DSC, LTPR için sırayla %85.59, %92.01 ile skorları alındığı görülmektedir. Bu skorlar veriseti ile test edilen modeller arasında en başarılı sonuca ulaşıldığını göstermektedir.

**Tablo 4.10.** MSAkdeniz Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları





DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%85.59	%75.03	%24.97	%92.01	%4.60	%92.14	%91.46	0.1153	4.5049	0.8226

Yapılan testlerde iMask R-CNN-R101-D ile MSAkdeniz verisetinde MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür. Şekil 4.25'de Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. MR görüntüleri incelendiğinde örtüşme oranının yüksekliği ve hata oranının düşüklüğü göze çarpmaktadır.

(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.25. MS Akdeniz Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde MS Lezyonu Başarıyla Tespit Edilen Bazı MR Görüntüleri

#### 4.6.6. MSAkdeniz Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi

MSAkdeniz veriseti üzerinde yapılan testlerde elde edilen sonuçlar Tablo 4.11’de detaylı olarak listelenmiştir. En başarılı sonuçlar koyu olarak öne çıkarılmıştır. Sonuçlar incelendiğinde; verisetinin kalitesinden ve lezyonların genel olarak büyük hacimde olmasından tüm modeller ile yapılan testler yüksek başarımlar seviyelerine ulaşmıştır. iMask R-CNN modeli çalışmanın genelinde diğer modellere göre başarılı sonuçlar vermiştir. iMask R-CNN-RX101-D modeli %85.59’luk DSC başarımları ile öne çıkmıştır ve yapılan testler sonucunda hatalı seçimlerin azlığı, lezyon olarak belirlenen alanların doğruluğu açısından en başarılı model olduğu görülmüştür.

**Tablo 4.11.** MSAkdeniz Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu


Model	DSC(%)	VOE(%)	ASD	HD95	AVD	LTPR(%)	LFPR(%)
U-Net	82.55	28.43	3.5675	15.8079	0.1649	92.01	12.76
Mask R-CNN-R101-K	83.64	<b>24.01</b>	4.2312	23.2923	0.2908	84.58	12.79
iMask R-CNN-R101-K	81.97	25.88	4.6402	22.1072	0.2571	85.38	15.13
iMask R-CNN-R101-D	83.47	28.49	1.5518	8.1089	0.1595	90.77	6.63
<b>iMask R-CNN-RX101-D</b>	<b>85.59</b>	24.97	<b>0.8226</b>	<b>4.5049</b>	<b>0.1153</b>	<b>92.02</b>	<b>4.60</b>

#### 4.7. eHealth Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar

Tez çalışması kapsamında hazırlanan veriseti üzerinde U-Net, Mask R-CNN-R101-K, iMask R-CNN-R101-K, iMask R-CNN-R101-D, iMask R-CNN-RX101-D derin öğrenme modellerinde eğitim ve testler gerçekleştirilmiştir. Bu bölümde eHealth veriseti ile yapılan tüm eğitim ve test süreçlerinin detaylarını ve başarılı örnek MR görselleri sunulmuştur.


##### 4.7.1. eHealth Verisetinde U-Net ile Elde Edilen Sonuçlar

eHealth veriseti üzerinde U-Net ile yapılan eğitimlerde veri arttırma katsayısı 4, ölçüm aralık çarpanı 10 olarak belirlenmiştir. Bu oranlar üzerinde 400 eğitim ve 120 test görüntüsünden oluşan veriseti 3762 eğitim ve 642 test verisine çıkarılmıştır. Her görüntüden ortalama 8 farklı versiyon üretilmiştir. Şekil 4.26’da eHealth verisetinin veri arttırma sonucu üretilen MR ve lezyon maskeleri örnekleri sunulmuştur.




**Şekil 4.26.** eHealth Verisetinin Veri Arttırma Sonucu Üretilen MR ve Lezyon Maskeleri

Arttırılmış veriler üzerinde 1000 tur eğitim gerçekleştirilmiş ve her 10 bir turda ağırlıklar kaydedilmiştir. Eğitimin test verileri bu ağırlıklar üzerinden hesaplanmıştır. Grafik 4.11’de eHealth verisetinin U-Net ile eğitimi sürecinde hata değişim grafiği görülmektedir. Bu grafik incelendiğinde hata oranının çok hızlı sıfır (0)’a yaklaştığı görülmüştür.



**Grafik 4.11.** eHealth Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği

eHealth veriseti üzerinde U-Net ile eğitim ve test çalışmaları başarıyla tamamlanmıştır. Grafik 4.12’de yapılan eğitimler sonucunda elde edilen ağırlıkların test veriseti üzerindeki DSC’nin değişimi görülmektedir. Grafikte de açıkça görüldüğü gibi U-Net modeli kullanılarak eHealth verisetinin eğitim sürecinde elde edilen ilk ağırlıklarda en başarılı sonuçlar elde edilmiştir. Ayrıca sonraki turlarda bu başarıya yakın sonuçlar alınmıştır.




**Grafik 4.12.** eHealth Veriseti ile U-Net Üzerinde Yapılan Testlerinin DSC Değişiminin Grafığı

eHealth veriseti üzerinde U-Net eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.12’de görülmektedir. DSC skorunun %65.29 ile düşük olmasından dolayı, lezyon alanlarının tam anlamıyla belirlenemediği ancak LTPR oranının %86.91 olması nedeniyle alan kapasitesinden bağımsız olarak lezyonların tespitinin başarılı olduğu görülmüştür. Yapılan testlerde U-Net ile eHealth veriseti üzerinde lezyon tespiti açısından başarı sağlandığı görülmüştür.

**Tablo 4.12.** eHealth Verisetinin U-Net ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%65.29	%50.49	%49.51	%86.91	%13.39	%66.23	%70.53	0.4189	39.7167	9.3543


Şekil 4.27’de U-Net modeli ile eHealth verisetinde başarıyla lezyon tespiti sağlanmış örnekler görülmektedir. Şekilde her görüntünün üstünde sırasıyla (a) orijinal MR görüntüsü, (b) uzman hekimlerin belirlediği lezyon alanları, (c) U-Net modelinin belirlediği lezyon alanları üstte verilmiş, bu görüntülerin altında (d)orijinal MR ve uzman görüşü (sarı renkli alanlar) ile sistem tahmini (kırmızı renkli alanlar) sonuçlarının örtüşmesi verilmiştir. Şekil incelendiğinde lezyon sınırları ile, sistem tahmini bölgelerinin tam örtüşmediği ancak lezyonların tamamının tespit edildiği açıkça görülmektedir.



**Şekil 4.27.** eHealth Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi


#### 4.7.2. eHealth Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonular

eHealth verisetinin Mask R-CNN-R101-K kullanarak yapılan eđitim sreci Grafik 4.13’de grlmektedir. Grafikte grlen genel hata eđitim srecinde maskeleme hatası, sınıf hatası, dođru blge belirleme hatası, belirlenen blgenin ierisinde maske alanının dođru belirlenmesi hatalarının toplamından oluřmaktadır. Hata verileri eđitim srecinde 100 tur iin ayrı ayrı kaydedilmiřtir. Grafik incelendiđine genel hatanın 2.5’den bařladıđı ve dzenli olarak dřtđ grlmektedir. Eđitim srecinin son turlarında sifıra yaklařtıđı ve eđitimin bařarı ile tamamlandıđı grlmektedir.



**Grafik 4.13.** eHealth Verisetinin Mask R-CNN-R101-K ile Yapılan Eđitim Srecinin Grafiđi

eHealth verisetinin Mask R-CNN-R101-K ile yapılan eđitimi 100 tur tekrarlanmıř ve her turda bir ađırlık kaydı yapılmıřtır. Bu ađırlıklar ile test seti zerinde yapılan incelemelerde DSC’nin deđiřimi Grafik 4.14’de grldđ gibidir. Bu grafik incelendiđinde sonuların test veriseti iin kararsız bir řekilde arttıđı grlmektedir. Bu durumun, verisetinin T2w sekansında olması nedeniyle eđitim srecinin zorluđu sonucunda meydana geldiđi deđerlendirilmiřtir.



**Grafik 4.14.** eHealth Verisetinin Mask R-CNN-R101-K ile Yapılan Eđitim Srecinde Elde Edilen Ađırlıkların DSC Benzerlik Katsayısı Deđiřimi

Mask R-CNN-R101-K eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.13'te verilmiştir. Bu tablodaki DSC skorunun %79.02 ve %82.00 olan LTPR oranına göre lezyon alanları ve lezyonların tespiti büyük oranda başarıyla sağlanmıştır.


**Tablo 4.13.** eHealth Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%79.02	%68.40	%31.59	%82.00	%22.01	%77.39	%81.67	0.6477	44,8948	11.4559

Yapılan testlerde Mask R-CNN-R101-K ile eHealth veriseti üzerinde önemli başarımlar sağlandığı görülmüştür. Şekil 4.28'de her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir.

#### 4.7.3. eHealth Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar


eHealth verisetinin iMask R-CNN-R101-K ile yapılan eğitim sürecinin hata değişimleri Grafik 4.15'te görülmektedir. Genel hata eğitim sürecinde maskeleme hatası, sınıf hatası, doğru bölge belirleme hatası, belirlenen bölgenin içerisinde maske alanının doğru belirlenmesi hatalarının toplamından oluşmaktadır. Grafik incelendiğinde genel hatanın hızlı düşüşü ve eğitim sürecinin sonunda sifıra yaklaşması eğitim sürecinin başarısını açıkça göstermektedir.



**Grafik 4.15.** eHealth Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği


(a) Uzman Seçimi (Ground Truth)

(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.28. eHealth Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

iMask R-CNN-R101-K ile yapılan eğitim 100 tur tekrarlanmış ve her turda bir ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.16'da görüldüğü gibidir. Test sürecinin başlarında yeterli başarımlar sağlanamamış ancak 40.turdan sonra DSC oranına göre kararlı bir yapı gözlenmiştir.



**Grafik 4.16.** eHealth Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi


eHealth verisetinin iMask R-CNN-R101-K eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.14'te verilmiştir. Tablo incelediğinde DSC'nin %84.59 ve LTPR'nin %90.80 gibi yüksek oranlarda olduğu görülmektedir. Bu sonuçlara göre eHealth verisetinde iMask R-CNN-R101-K ile lezyon alanları ve lezyonlar büyük bir başarıyla tespit edilmiştir.

**Tablo 4.14.** eHealth Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları






DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%84.59	%76.25	%23.75	%90.80	%15.71	%83.51	%90.71	0.5743	37.3468	9.1210

Yapılan testlerde iMask R-CNN-R101-K ile eHealth veriseti üzerinde önemli başarımlar sağlandığı görülmüştür. Şekil 4.29'da her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. Bu örnekler incelendiğinde lezyon alanlarının sınırlarının ve lezyonların önemli oranda başarıyla tespit edildiği görülmektedir.

(a) Uzman Seçimi (Ground Truth)




(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.29. eHealth Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri


#### 4.7.4. eHealth Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonular

eHealth verisetinin iMask R-CNN-R101-D ile yapılan eđitim srecinin hata deđişimleri Grafik 4.17’de grlmektedir. Genel hata eđitim srecinde maskeleme hatası, sınıf hatası, dođru blge belirleme hatası, belirlenen blgenin ierisinde maske alanının dođru belirlenmesi hatalarının toplamından oluřmaktadır. Grafik incelendiđinde genel hatanın 1’den bařladıđı ve hızla sifira yaklařtıđı grlmřtr.



**Grafik 4.17.** eHealth Verisetinin iMask R-CNN-R101-D ile Yapılan Eđitim Srecinin Grafiđi

eHealth verisetinin iMask R-CNN-R101-D ile yapılan eđitim srecinde her periyot noktası iin ađırlık kaydı yapılmıřtır. Bu ađırlıklar ile test seti zerinde yapılan incelemelerde oluřan DSC deđiřimi Grafik 4.18’de grldđuđu gibidir. Grafiđin tm turların testinde kararlılıkla sonu verdiđi grlmektedir. En iyi tur sonucunu iřaretleterek ne ıkarılmıřtır.



**Grafik 4.18.** eHealth Verisetinin iMask R-CNN-R101-D Eđitim Srecin DSC Deđiřim Grafiđi

iMask R-CNN-R101-D eđitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.15’te grlmektedir. iMask R-CNN-R101-D ile yapılan testlerde eHealth verisetinin MS lezyonlarının bařarıyla tespitinin sađlandıđı grlmřtr. Yapılan

incelemede DSC skorunun %86.47 ve LTPR oranının %86.87 olduğu ve lezyon tespiti açısından yüksek skorlar alındığı görülmüştür. Bu skorlara göre, eHealth verisetinin iMask R-CNN-R101-D modeli ile otomatik lezyon tespitinin başarıyla yapılmıştır.


**Tablo 4.15.** eHealth Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%86.47	%78.97	%21.02	%86.87	%8.69	%90.26	%86.56	0,3652	29.9711	4.1570


En iyi tur sonucunda başarıyla tespit edilen lezyon örnekleri Şekil 4.30'da görülmektedir. Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. MR kesiti örnekleri incelendiğinde, tespit başarımının yüksekliği açıkça görülmektedir.

#### 4.7.5. eHealth Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar

eHealth verisetinin iMask R-CNN-RX101-D modeli ile yapılan eğitim sürecinin hata değişimleri Grafik 4.19'da görülmektedir. Bu grafik incelendiğinde genel hatanın düşük bir noktadan başladığı görülmektedir. Grafiğin hızla sıfıra düşmesi eğitim sürecinin başarımını ortaya koymaktadır.




**Grafik 4.19.** eHealth Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Grafiği



**Şekil 4.30.** eHealth Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

eHealth verisetinin iMask R-CNN-RX101-D ile yapılan eğitimlerinde elde edilen ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.20'de görüldüğü gibidir. Burada başarı oranının ilk turdan itibaren yüksek olduğu ve büyük değişim yaşamadan belli bir aralıkta seyrettiği görülmektedir.



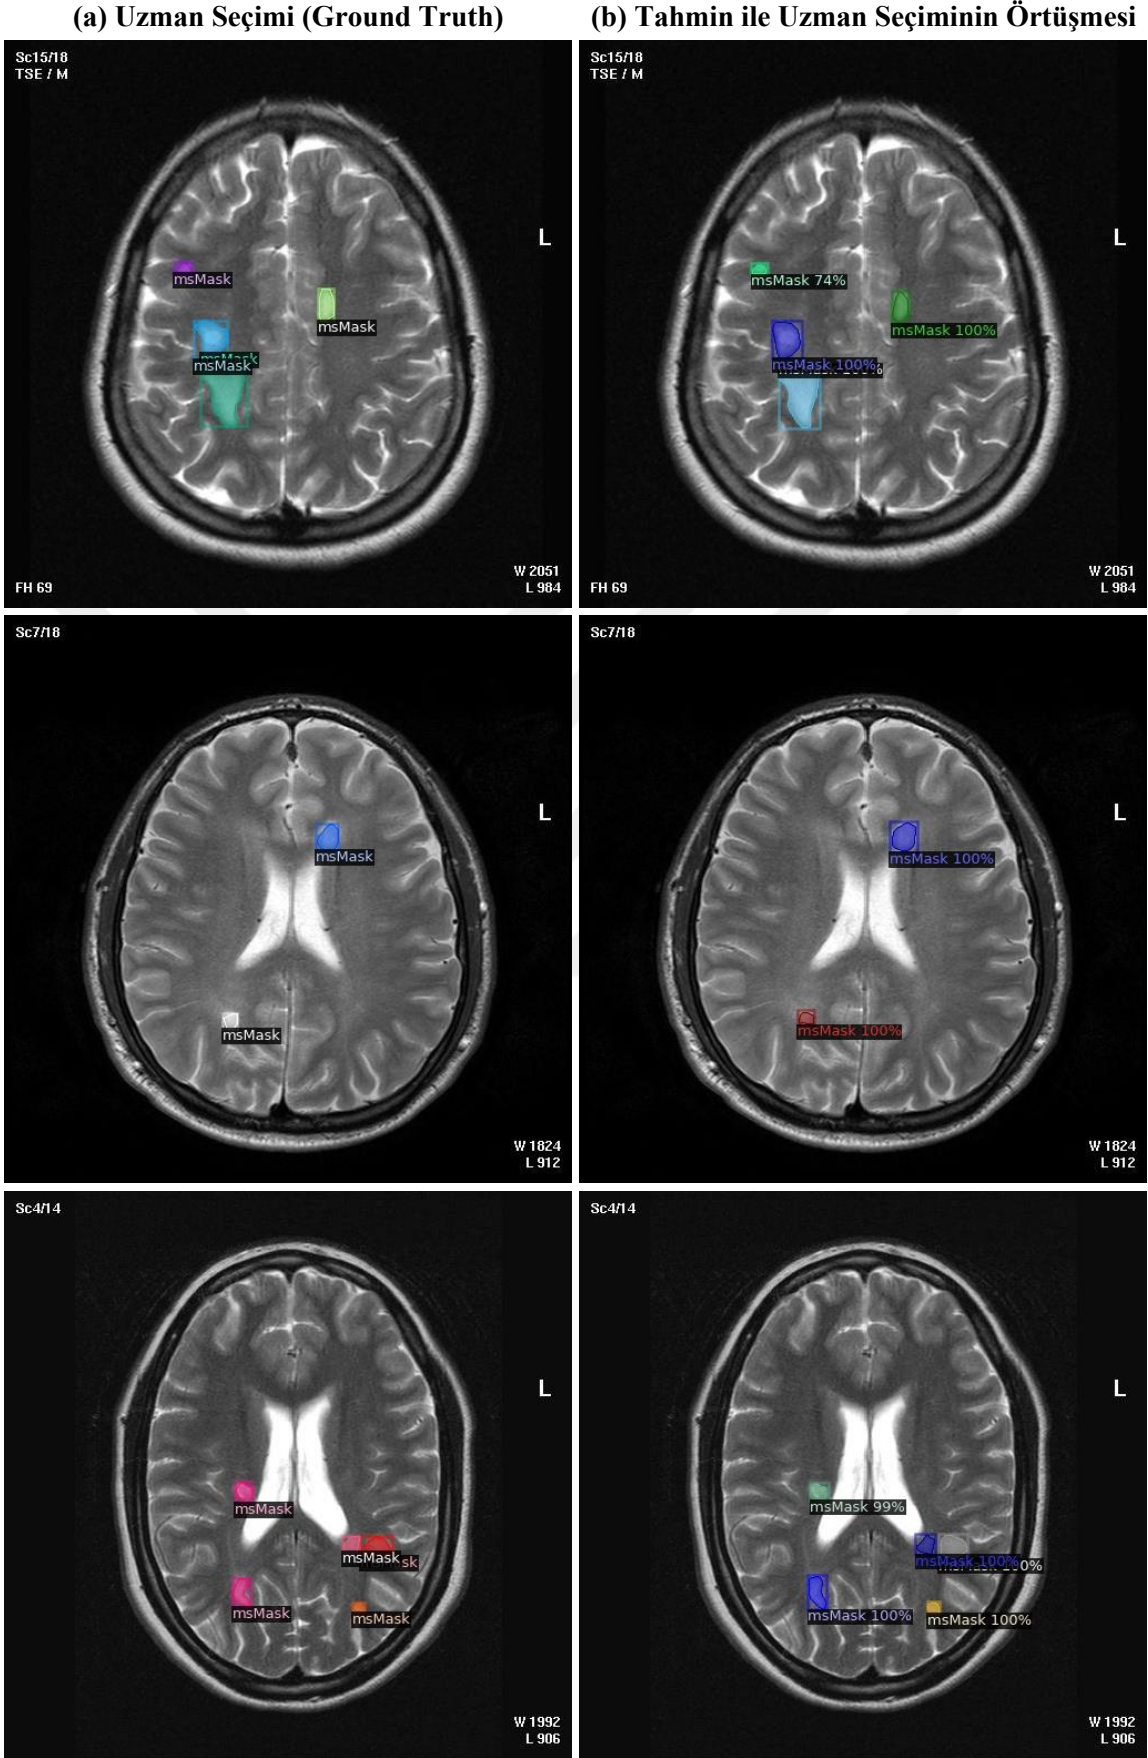
**Grafik 4.20.** eHealth iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin DSC Değişimi

iMask R-CNN-RX101-D modeli ile eHealth verisetinde yapılan eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.16'da görülmektedir. Bu tablo incelendiğinde, DSC skorunun %89.00 ve LTPR oranının %86.86 olduğu ve LFPR oranını %4.89 gibi düşük bir değer aldığı görülmüştür. Bu sonuçlara göre otomatik lezyon tespiti büyük başarı ile gerçekleştirilmiştir.

**Tablo 4.16.** eHealth Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%89.00	%82.54	%17.45	%86.86	%4.89	%94.32	%86.81	0,3203	24.3147	2.7226

eHealth verisetinin iMask R-CNN-RX101-D ile yapılan eğitimlerinde en iyi turda elde edilen ağırlık ile yapılan testlerde alınan başarıyla tespit edilen lezyon örnekleri Şekil 4.31'de görülmektedir. Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. Şekil incelendiğinde otomatik tespit edilen alanlar ile uzman görüşleri arasındaki örtüşme başarıları açıkça görülmektedir.



**Şekil 4.31.** eHealth Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

#### 4.7.6. eHealth Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi

eHealth veriseti üzerinde yapılan testlerde elde edilen sonuçlar Tablo 4.17’de detaylı olarak listelenmiştir. En başarılı sonuçlar koyu olarak öne çıkarılmıştır. Sonuçlar incelendiğinde; verisetinde iMask R-CNN-RX101-D modelinin üstün başarı sergilediği tüm metrikler üzerinde açıkça görülmektedir. Detectron2 ortamının Keras ortamına göre daha iyi sonuçlar sergilediği de metriklerde gözlenmektedir. Ayrıca ResNeXt101 omurga yapısının ResNet101 ortamına göre etkin fark sağladığı da sonuçlarda açıkça görülmektedir. Tez kapsamında geliştirilen derin öğrenme modelinin bu verisetinde başarıyı sağladığı açıkça görülmüştür.

**Tablo 4.17.** eHealth Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu


Model	DSC%	VOE(%)	ASD	HD95	AVD	LTPR(%)	LFPR(%)
U-Net	65.29	49.51	9.3543	39.7167	0.4189	86.91	13.39
Mask R-CNN-R101-K	79.02	31.59	11.4559	44.8948	0.6477	82.00	22.01
iMask R-CNN-R101-K	84.59	23.75	9.1210	37.3468	0.5743	<b>90.80</b>	15.71
iMask R-CNN-R101-D	86.47	21.02	4.1570	29.9711	0,3652	86.87	8.69
<b>iMask R-CNN-RX101-D</b>	<b>89.00</b>	<b>17.45</b>	<b>2.7226</b>	<b>24.3147</b>	<b>0.3203</b>	86.86	<b>4.89</b>

#### 4.8. UMCL Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar

Tez çalışması kapsamında Ljubljana Üniversitesi’nin bilim dünyasına sunduğu UMCL veriseti üzerinde U-Net, Mask R-CNN-R101-K, iMask R-CNN-R101-K, iMask R-CNN-R101-D, iMask R-CNN-RX101-D derin öğrenme modellerinde eğitim ve testler gerçekleştirilmiştir. Bu bölümde UMCL veriseti ile yapılan tüm eğitim ve test süreçlerinin detayları, başarılı örnek MR görselleri sunulmuştur.


##### 4.8.1. UMCL Verisetinde U-Net ile Elde Edilen Sonuçlar

Veriseti üzerinde U-Net ile yapılan eğitimlerde veri artırma katsayısı 4, ölçüm aralık çarpanı 1 olarak belirlenmiştir. Bu oranlar üzerinde 500 eğitim ve 100 test görüntüsünden oluşan veriseti 3890 eğitim ve 787 test verisine çıkarılmıştır. Her görüntüden ortalama 8 farklı versiyon üretilmiştir. Şekil 4.32’de UMCL verisetinde veri artırma işlemi uygulanarak elde edilmiş MR görüntülerine örnekler sunulmuştur.




**Şekil 4.32.** UMCL Verisetinin Veri Arttırma İşlemi ile Elde Edilmiş MR Görüntülerine ve Lezyon Maskeleri

Arttırılmış veriler üzerinde 100 tur eğitim gerçekleştirilmiş ve her turda ağırlıklar kaydedilmiştir. Eğitimin test verileri bu ağırlıklar üzerinden hesaplanmıştır. Grafik 4.21’de UMCL verisetinin U-Net ile eğitimi sürecinde hata değişim grafiği görülmektedir. Grafik incelendiğinde eğitim sürecinin daha ilk adımlarında hatanın hızla sifıra yaklaştığı görülmektedir.



**Grafik 4.21.** UMCL Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği

UMCL veriseti üzerinde U-Net ile eğitim ve test çalışmaları başarıyla tamamlanmıştır. Grafik 4.22’de yapılan eğitimler sonucunda elde edilen ağırlıkların test veriseti üzerindeki DSC benzerlik katsayısındaki değişim görülmektedir. Sonuçlar incelendiğinde eğitim süreç grafiğine benzer şekilde test süreçlerinin de ilk turlardan itibaren kararlı şekilde sonuçlar verdiği görülmektedir.




**Grafik 4.22.** UMCL Veriseti Üzerinde Yapılan U-Net Testlerinin DSC Benzerlik Değişimi

U-Net eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.18’de görülmektedir. Bu tabloda bulunan %79.42’lik DSC skoru lezyon alanlarının büyük bölümünün, %83.68’lik LTPR oranı ise lezyonların büyük bölümünün otomatik tespitinin başarıyla sağlandığını göstermektedir.

**Tablo 4.18.** UMCL Verisetinin U-Net ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%79.42	%69.38	%30.10	%83.68	%21.26	%86.18	%77.25	0.1641	28.575	4.723


Yapılan testlerde U-Net ile UMCL veriseti üzerinde önemli başarımlar sağlandığı görülmüştür. Şekil 4.33’te UMCL veriseti üzerinde U-Net ile yapılan testlerde başarıyla MS lezyonu tespit edilmiş görüntü örnekleri görülmektedir. Burada her görüntünün üstünde sırasıyla (a) orijinal MR görüntüsü, (b) uzman hekimlerin belirlediği lezyon alanları, (c) U-Net modelinin belirlediği lezyon alanları üstte verilmiş, bu görüntülerin altında (d)orijinal MR ve uzman görüşü (sarı renkli alanlar) ile sistem tahmini (kırmızı renkli alanlar) sonuçlarının örtüşmesi verilmiştir. Şekil incelendiğinde MR kesitleri üzerinde uzman görüşleri ile otomatik tespit edilen lezyon alanlarının örtüşmesi görülmektedir.



**Şekil 4.33.** UMCL Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi


#### 4.8.2. UMCL Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonular

UMCL verisetinin Mask R-CNN-R101-K kullanarak yapılan eđitim süreci Grafik 4.23'te grlmektedir. Genel hata deđerinin diđer testlere gre daha yksek bir seviyeden bařladıđı ancak eđitim sürecinin sonlarına dođru sifira yaklařtıđı grafikte aıka grlmektedir.



**Grafik 4.23.** UMCL Verisetinin Mask R-CNN-R101-K ile Yapılan Eđitim Srecinin Grafiđi

Mask R-CNN-R101-K ile yapılan eđitim 100 tur tekrarlanmıř ve her turda bir ađrılık kaydı yapılmıřtır. Bu ađrılıklar ile test seti zerinde yapılan incelemelerde DSC'nin deđiřimi Grafik 4.24'te grldđi gibidir. Tm sre boyunca test bařarımının arttıđı grlmektedir.



**Grafik 4.24.** UMCL Verisetinin Mask R-CNN-R101-K ile Yapılan Eđitim Srecinde Elde Edilen Ađrılıkların DSC Benzerlik Katsayısı Deđiřimi

Mask R-CNN-R101-K eđitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.19'da verilmiřtir. Yapılan testlerde Mask R-CNN-R101-K ile UMCL veriseti zerinde nemli bařarım sađlandıđı grlmřtr. Tablo incelendiđinde lezyon alanlarının seim bařarısının %82.35 DSC ile sađlandıđı grlmektedir. Ayrıca, LFPR oranının %7.98 ile dřk bir seviyede kalması hatalı lezyon seiminin azlıđını gstermektedir.


**Tablo 4.19.** UMCL Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%82.35	%72.61	%27.39	%80.42	%7.98	%91.25	%78.34	0.3404	21.5365	3.1984

Şekil 4.34'te Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. Bu MR görüntüleri incelendiğinde; uzman seçimi ve otomatik tespit edilen lezyon alanlarının örtüşme başarımının yüksekliği anlaşılmaktadır.

#### 4.8.3. UMCL Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar


UMCL verisetinin iMask R-CNN-R101-K ile yapılan eğitim sürecinin hata değişimleri Grafik 4.25'te görülmektedir. Bu grafikteki genel hatanın hızla sıfıra inmesi eğitim sürecinin başarıyla ilerlediğini ve tamamlandığını göstermektedir.








**Grafik 4.25.** UMCL Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği

UMCL verisetinde iMask R-CNN-R101-K ile yapılan eğitim 100 tur tekrarlanmış ve her turda bir ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.26'da görüldüğü gibidir. Burada test verilerinde yapılan incelemede başarımın hızla yükseldiği ve belli bir seviyede seyrettiği ve eğitim sürecindeki genel hata değişimi ile benzer bir karakteristik yapı izlediği görülmektedir.


(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.34. UMCL Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri



**Grafik 4.26.** UMCL Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi


iMask R-CNN-R101-K eğitimlerinde UMCL verisetinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.20’de verilmiştir. Buradaki skorlardan %84.84 DSC, %86.14 LTPR değerleri etkili bir bölütleme yapıldığını göstermektedir. Yapılan testlerde iMask R-CNN-R101-K ile UMCL veriseti üzerinde önemli başarımlar sağlandığı görülmüştür.

**Tablo 4.20.** UMCL Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları






DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%84.84	%75.75	%24.25	%86.14	%9.79	%89.43	%83.53	0.3678	17.5128	3.4712

Şekil 4.35’te Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir. Otomatik tespit edilen lezyon alanları ile uzmanlar tarafından seçimi yapılan alanların başarıyla örtüştüğü görülmektedir.

(a) Uzman Seçimi (Ground Truth)




(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.35. UMCL Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri


#### 4.8.4. UMCL Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonular

UMCL verisetinin iMask R-CNN-R101-D ile yapılan eđitim srecinin hata deđiřimleri Grafik 4.27’de grlmektedir. Grafik 100.000 iterasyon devam eden eđitim srecinde her 100 iterasyon da 1 kez olmak zere 1000 defa kaydedilen hata verilerini iermektedir. Burada eđitim srecinin hızla bařarıya ulařtıđı aıka grlmektedir.



**Grafik 4.27.** UMCL Verisetinin iMask R-CNN-R101-D ile Yapılan Eđitim Srecinin Grafiđi

Yapılan eđitim srecinde elde edilen ađırlıklar ile test seti zerinde yapılan incelemelerde oluřan DSC deđiřimi Grafik 4.28’de grldđi gibi. Bu ađırlıkların test setinde kararlı bir Őekilde bařarım sađladıđı grlmřtr.



**Grafik 4.28.** UMCL Verisetinin iMask R-CNN-R101-D Testlerinde DSC Deđiřim Grafiđi

iMask R-CNN-R101-D eđitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.21’de grlmektedir. iMask R-CNN-R101-D ile yapılan testlerde UMCL verisetinin MS lezyonlarının bařarıyla tespitinin sađlandıđı grlmřtr. Tablo incelendiđinde DSC skorunun %92.24 gibi ok yk bir bařarıma ulařıldıđı ve LFPR %3.27 ile

çok düşük bir hata oranının yakalandığı görülmektedir. Bu skorlar UMCL verisetinde iMask R-CNN-R101-D ile otomatik lezyon tespiti başarıyla sağlandığını göstermektedir.


**Tablo 4.21.** UMCL Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%92.24	%86.90	%13.10	%92.45	%3.27	%94.19	%91.31	0.0715	1.7665	0.2356

UMCL verisetinin iMask R-CNN-R101-D ile yapılan testler sonucunda başarıyla tespit edilen lezyon örnekleri Şekil 4.36’da görülmektedir. Buradaki MR kesitleri incelendiğinde lezyon alanları ile uzman görüşlerinin örtüşme başarımı açıkça görülmektedir.

#### 4.8.5. UMCL Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar


UMCL verisetinin iMask R-CNN-RX101-D modeli ile yapılan eğitim sürecinin hata değişimleri Grafik 4.29’da görülmektedir. Grafik eğitim sürecinin başından itibaren düşük hata oranı ile hızla tamamlandığını göstermektedir.








**Grafik 4.29.** UMCL Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Grafiği

UMCL verisetinin iMask R-CNN-RX101-D ile yapılan eğitim sürecinde her 1000 iterasyonda bir periyot noktası belirlenmiş ve ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde oluşan DSC değişimi Grafik 4.30’da görüldüğü gibidir. Bu grafik incelendiğinde test sürecinin başarıyla ve kararlılıkla tamamlandığı açıkça görülmektedir.


(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.36. UMCL Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri



**Grafik 4.30.** UMCL Verisetinin iMask R-CNN-RX101-D Eğitim Sürecin DSC Değişim Grafiği


Tablo 4.22’de UMCL verisetinin iMask R-CNN-RX101-D eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları görülmektedir. DSC ve LTPR metrikleri incelendiğinde %91.70 ve %91.08 gibi çok yüksek bir başarıma ve LFPR bakımından %3.14 ile çok küçük bir hata oranına ulaşılmıştır. Bu sonuçlara göre; iMask R-CNN-RX101-D ile yapılan testlerde UMCL verisetinin MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür.

**Tablo 4.22.** UMCL Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları





DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%91.70	%85.97	%14.03	%91.08	%3.14	%94.77	%90.01	0.0661	1.9096	0.2904

Başarıyla tespit edilen lezyon örnekleri Şekil 4.37’de görülmektedir. Şekilde her sırada aynı MR görüntüsünün önce uzman hekimlerin belirlediği lezyonlar işaretlenmiş versiyonu ardından sistem tarafından lezyon bölgesi olarak belirlenen alanlar görülmektedir.

(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.37. UMCL Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

#### 4.8.6. UMCL Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi

UMCL veriseti üzerinde yapılan testlerde elde edilen sonuçlar Tablo 4.23'te detaylı olarak listelenmiştir. En başarılı sonuçlar koyu olarak öne çıkarılmıştır. Sonuçlar incelendiğinde; iMask R-CNN-R101-D modelinin en başarılı model olduğu ve örtüşme oranlarında büyük başarı gösterdiği gözlenmiştir. ResNeXt101 kullanılan model iMask R-CNN-RX101-D'nin AVD ve LFPR oranlarındaki başarısı ile öne çıktığı görülmüştür.

**Tablo 4.23.** UMCL Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu


Model	DSC%	VOE(%)	ASD	HD95	AVD	LTPR(%)	LFPR(%)
U-Net	79.42	30.10	4.723	28.5750	0.1641	83.68	21.26
Mask R-CNN-R101-K	82.35	27.39	3.1984	21.5365	0.3404	80.42	7.98
iMask R-CNN-R101-K	84.84	24.25	3.4712	17.5128	0.3678	86.14	9.79
<b>iMask R-CNN-R101-D</b>	<b>92.24</b>	<b>13.10</b>	<b>0.2356</b>	<b>1.7665</b>	0.0715	<b>92.45</b>	3.27
iMask R-CNN-RX101-D	91.70	14.03	0.2904	1.9096	<b>0.0661</b>	91.08	<b>3.14</b>

#### 4.9. ISBI2015 Veriseti ile Yapılan Testler ve Elde Edilen Sonuçlar

Tez çalışması kapsamında 12. Uluslararası Biyomedikal Görüntüleme Sempozyumu kapsamında düzenlenen yarışma veriseti ISBI2015 üzerinde U-Net, Mask R-CNN-R101-K, iMask R-CNN-R101-K, iMask R-CNN-R101-D, iMask R-CNN-RX101-D derin öğrenme modellerinde eğitim ve testler gerçekleştirilmiştir. Bu bölümde ISBI2015 veriseti ile yapılan tüm eğitim ve test süreçlerinin detayları ve başarılı örnek MR görselleri sunulmuştur.


##### 4.9.1. ISBI2015 Verisetinde U-Net ile Elde Edilen Sonuçlar

ISBI2015 veriseti üzerinde U-Net ile yapılan eğitimlerde veri arttırma katsayısı 4, ölçüm aralık çarpanı 1 olarak belirlenmiştir. Bu oranlar üzerinde 500 eğitim ve 100 test görüntüsünden oluşan veriseti 3890 eğitim ve 787 test verisine çıkarılmıştır. Her görüntüden ortalama 8 farklı versiyon üretilmiştir. Şekil 4.38'de ISBI2015 verisetinde veri arttırma işlemi uygulanarak elde edilmiş MR görüntülerine örnekler sunulmuştur.




**Şekil 4.38.** ISBI2015 Verisetinin Veri Arttırma Sonucu Üretilen MR ve Lezyon Maskeleri Örnekleri

Arttırılmış veriler üzerinde 100 tur eğitim gerçekleştirilmiş ve her turda ağırlıklar kaydedilmiştir. Eğitimin test verileri bu ağırlıklar üzerinden hesaplanmıştır. Grafik 4.31’de ISBI2015 verisetinin U-Net ile eğitimi sürecinde hata değişim grafiği görülmektedir. Eğitim sürecinde hata oranının hızla sıfıra yaklaştığı görülmüştür.



**Grafik 4.31.** ISBI2015 Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği

ISBI2015 veriseti üzerinde U-Net ile eğitim ve test çalışmaları başarıyla tamamlanmıştır. Grafik 4.32’de yapılan eğitimler sonucunda elde edilen ağırlıkların test veriseti üzerindeki DSC’nin değişimi görülmektedir. Bu grafikte test verileri üzerinde kararlı bir sonuç alındığı görülmektedir. Eğitim sürecindeki başarımlar test süreçlerinde de izlenmektedir.




**Grafik 4.32.** ISBI2015 Veriseti ile U-Net Üzerinde Yapılan Testlerinin DSC Değişiminin Grafiği

ISBI2015 veriseti üzerinde U-Net eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.24’te görülmektedir. Tablodaki DSC skoru %78.93 ile lezyon alanlarının etkili bir şekilde tespit edildiği, LTPR oranı ise %93.34 ile lezyonların çoğunluğunun otomatik olarak tespit edilebildiğini göstermektedir.

**Tablo 4.24.** ISBI2015 Verisetinin U-Net ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%78.93	%66.90	%33.09	%93.34	%14.07	%81.99	%78.91	0.1731	10.9092	1.9569


Yapılan testlerde U-Net ile ISBI2015 veriseti üzerinde önemli başarımlar sağlandığı görülmüştür. Şekil 4.39’da her görüntünün üstünde sırasıyla (a) orijinal MR görüntüsü, (b) uzman hekimlerin belirlediği lezyon alanları, (c) U-Net modelinin belirlediği lezyon alanları üstte verilmiş, bu görüntülerin altında (d) orijinal MR ve uzman görüşü (sarı renkli alanlar) ile sistem tahmini (kırmızı renkli alanlar) sonuçlarının örtüşmesi verilmiştir. Şekilde lezyon alanları ile uzman seçimlerinin başarıyla örtüşmesi görülmektedir.



**Şekil 4.39.** ISBI2015 Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi


#### 4.9.2. ISBI2015 Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar

ISBI2015 verisetinin Mask R-CNN mimarisinin standart versiyonu ile ResNet101 omurga yapısını (Mask R-CNN-R101-K) kullanarak yapılan eğitim süreci Grafik 4.33'te görülmektedir. Genel hata eğitim sürecinde maskeleme hatası, sınıf hatası, doğru bölge belirleme hatası, belirlenen bölgenin içerisinde maske alanının doğru belirlenmesi hatalarının toplamından oluşmaktadır. Grafik incelendiğinde; eğitim sürecinde hata oranının düşüş hızı açıkça görülmektedir.



**Grafik 4.33.** ISBI2015 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği

Mask R-CNN-R101-K ile yapılan eğitim 100 tur tekrarlanmış ve her turda bir ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.34'te görüldüğü gibidir. Bu değişim grafiği incelendiğinde; test sürecinin belli bir kararlılıkla seyrettiği görülmektedir. En başarılı tur sonucu işaretlenerek öne çıkarılmıştır.



**Grafik 4.34.** ISBI2015 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi

Mask R-CNN-R101-K eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.25’de verilmiştir. Tabloda en iyi tur da %86.91 DSC skoru ve %87.23 LFPR oranına ulaşıldığı ve başarılı şekilde lezyon bölütlemesi yapıldığı görülmektedir.

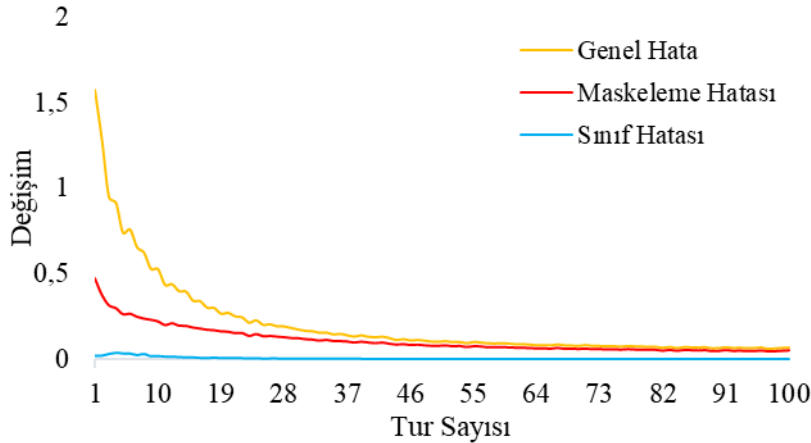
**Tablo 4.25.** ISBI2015 Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%86.91	%81.06	%18.94	%87.23	%10.36	%90.74	%86.71	0,3158	18.8129	4.4903

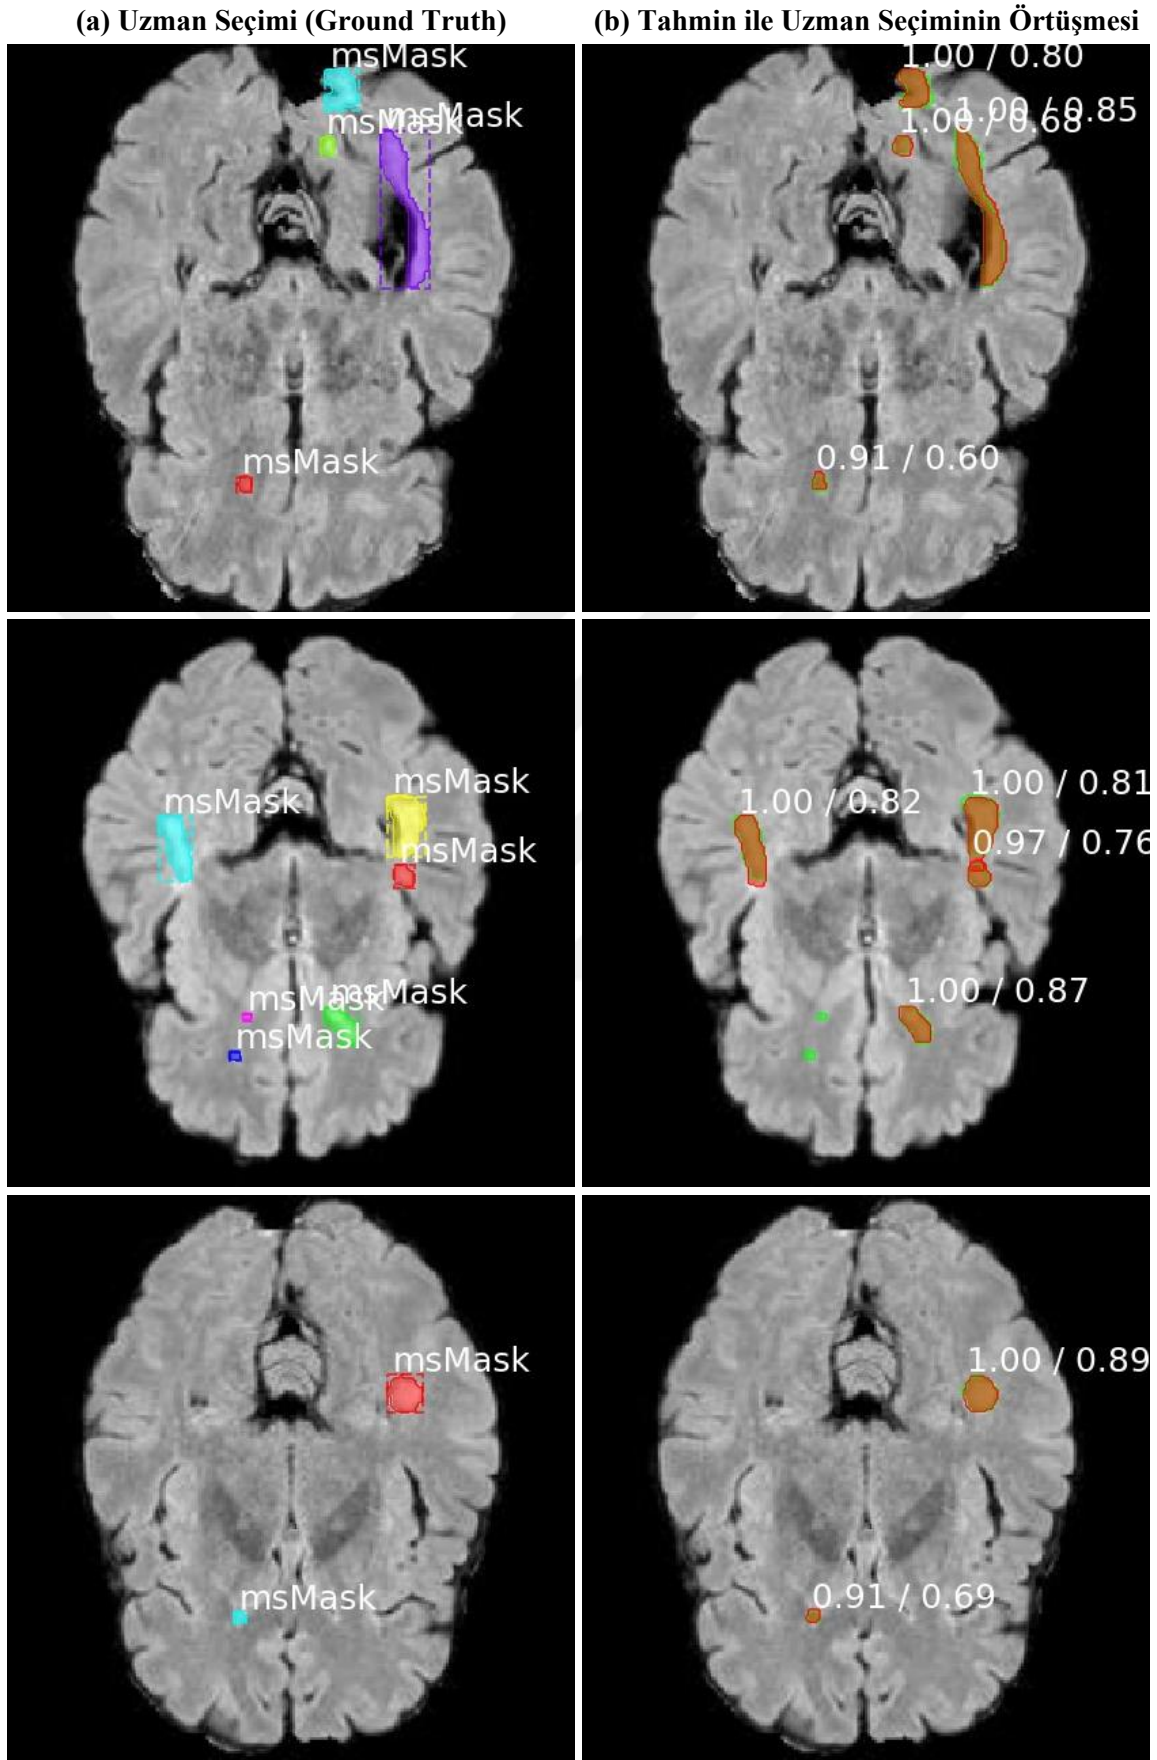
Yapılan testlerde Mask R-CNN-R101-K ile ISBI2015 veriseti üzerinde önemli başarımlar sağlandığı görülmüştür. Şekil 4.40’da her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri ve otomatik tespit edilen lezyon alanları ile uzman görüşlerinin uyumu görülmektedir.

#### 4.9.3. ISBI2015 Verisetinde iMask R-CNN-R101-K ile Elde Edilen Sonuçlar

ISBI2015 verisetinin iMask R-CNN-R101-K ile yapılan eğitim sürecinin hata değişimleri Grafik 4.35’te görülmektedir. Burada genel hatanın sıfıra çok hızlı bir şekilde yaklaştığı görülmekte ve bu nedenle eğitim sürecinin başarıyla tamamlandığı anlaşılmaktadır.




**Grafik 4.35.** ISBI2015 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği



**Şekil 4.40.** ISBI2015 Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

ISBI2015 verisetinin iMask R-CNN-R101-K ile yapılan eğitimin her turunda bir ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test setinde yapılan incelemelerde DSC'nin değişimi Grafik 4.36'da görüldüğü gibidir. Bu grafik elde edilen ağırlıkların test seti için yakın sonuçlar verdiğini göstermektedir.




**Grafik 4.36.** ISBI2015 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi

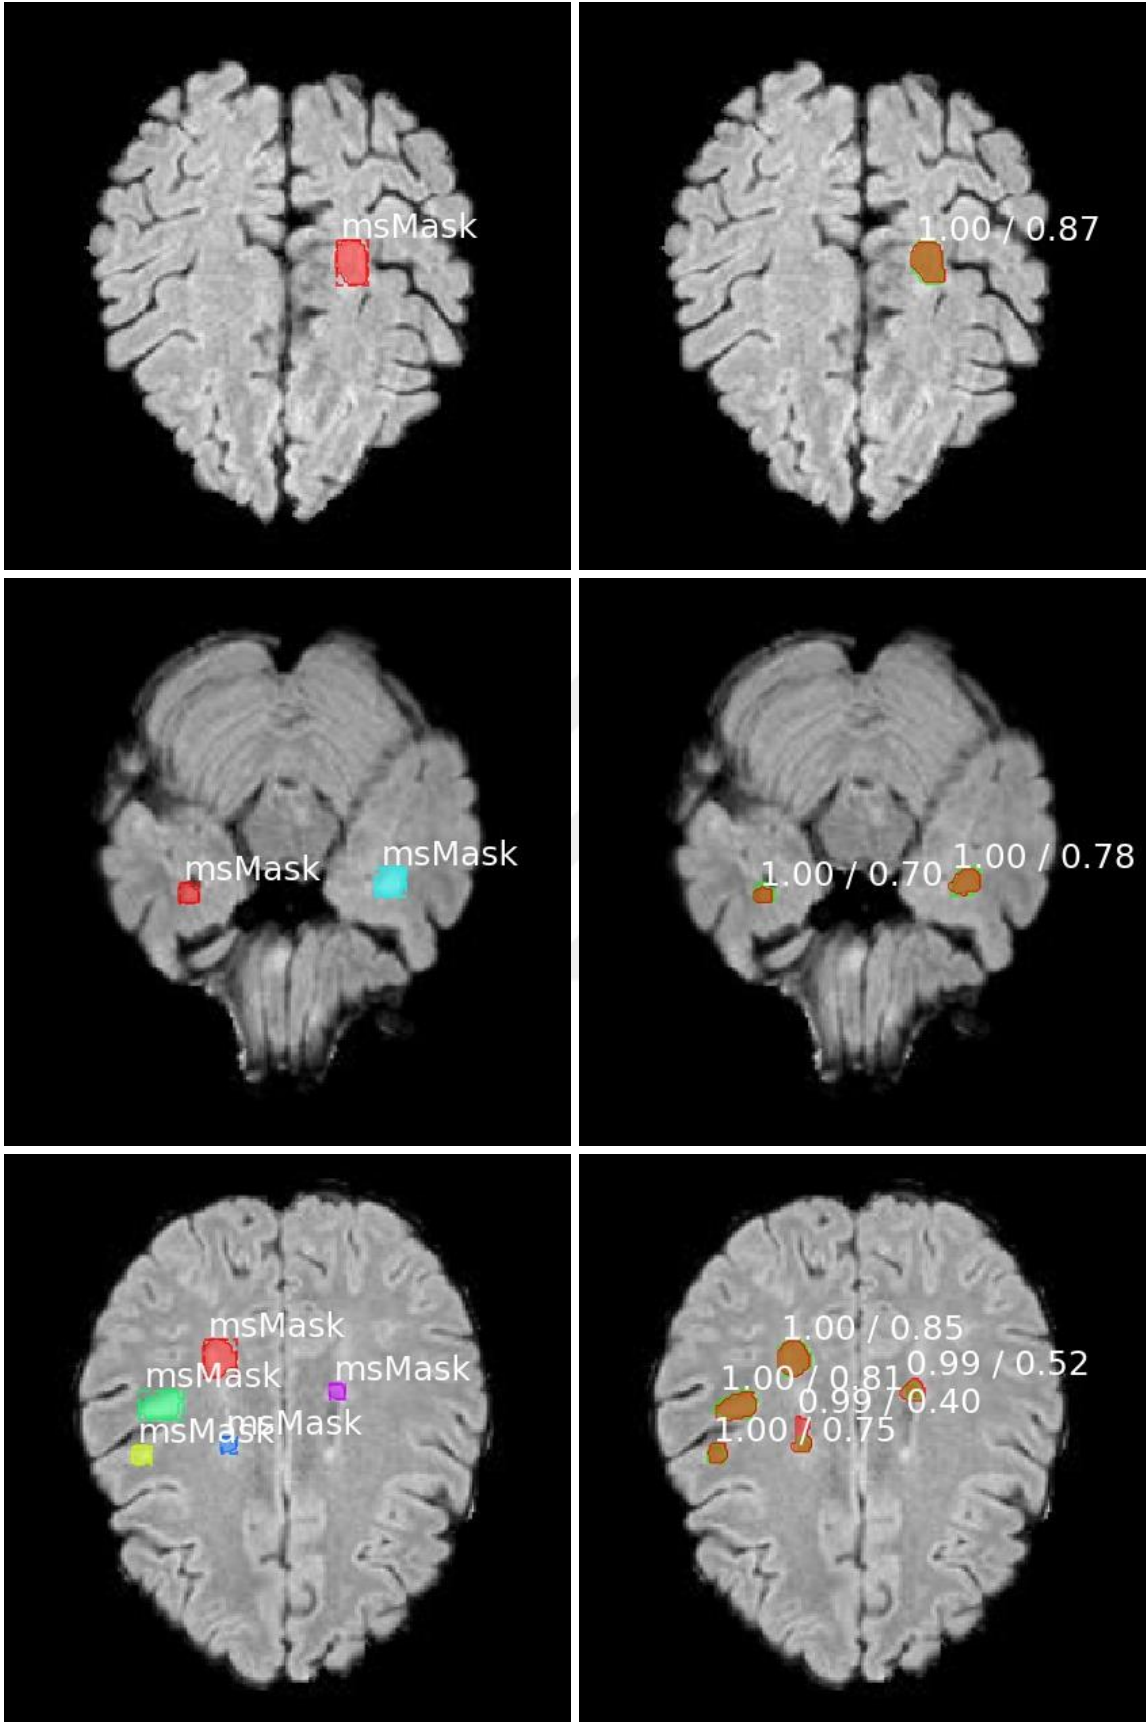
Yapılan testlerde ISBI2015 veriseti ile iMask R-CNN-R101-K de önemli başarımlar sağlandığı görülmüştür. Şekil 4.41'de her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri ve otomatik tespit edilen lezyon alanları ile uzman görüşlerinin uyumu görülmektedir.

#### 4.9.4. ISBI2015 Verisetinde iMask R-CNN-R101-D ile Elde Edilen Sonuçlar

ISBI2015 verisetinin iMask R-CNN-R101-D ile yapılan eğitim sürecinin hata değişimleri Grafik 4.37'de görülmektedir. Bu grafik eğitim sürecinin başarısını açıkça göstermektedir.




**Grafik 4.37.** ISBI2015 Verisetinin iMask RCNN-R101-D ile Yapılan Eğitim Sürecinin Grafığı  
(a) Uzman Seçimi (Ground Truth) (b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.41. ISBI2015 Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntülerine Örnekler

ISBI2015 verisetinde iMask R-CNN-R101-D ile yapılan eğitim sürecinde her 1000 iterasyonda bir periyot noktası belirlenmiş ve ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde oluşan DSC değişimi Grafik 4.38’de görüldüğü gibidir. Grafikte görüldüğü gibi bu modelde eğitim maksimum başarıma 12. turda erişmiştir ve tüm test işlemlerinde yakın sonuçlar alınarak kararlı bir yol izlediği görülmüştür.



**Grafik 4.38.** ISBI2015 Verisetinin iMask R-CNN-R101-D Eğitim Sürecin DSC Değişimi


iMask R-CNN-R101-D modeli ile ISBI2015 verisetinin testlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.26’da görülmektedir. Tablo incelendiğinde, DSC ve LTPR açısından %89.44, %89.67 skorları ile etkili bir şekilde lezyon bölütlemesi yapıldığı ve LFPR oranının %4.11 gibi düşük olması ile lezyon tespit hatasını düşük olduğu anlaşılmaktadır. Yapılan testlerde ISBI2015 verisetinin MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür.

**Tablo 4.26.** ISBI2015 Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%89.44	%83.29	%16.70	%89.67	%4.11	%94.52	%88.17	0.1726	8.6711	0.8329

Başarıyla tespit edilen lezyon örnekleri Şekil 4.42’de görülmektedir. Şekilde her sırada aynı MR görüntüsünün önce uzman hekimlerin belirlediği lezyonlar işaretlenmiş versiyonu ardından sistem tarafından lezyon bölgesi olarak belirlenen alanlar sunulmuştur. Lezyon alanları ile otomatik tespit alanlarının büyük bir başarıyla örtüşmesi şekilde açıkça görülmektedir.


(a) Uzman Seçimi (Ground Truth) (b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.42. ISBI2015 Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri


#### 4.9.5. ISBI2015 Verisetinde iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar

ISBI2015 verisetinin iMask R-CNN-RX101-D modeli ile yapılan eğitim sürecinin hata değişimleri Grafik 4.39’da görülmektedir. Eğitim sürecinde genel hata oranının sıfıra doğru hızla indiği görülmektedir.



**Grafik 4.39.** ISBI2015 Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Hata Değişimi

ISBI2015 verisetinin iMask R-CNN-RX101-D ile yapılan eğitim sürecinde her 1000 iterasyonda bir periyot noktası belirlenmiş ve ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde oluşan DSC değişimi Grafik 4.40’da görüldüğü gibidir. Grafikte testler boyunca bir modelin bir kararlılık sergilediği açıkça görülmektedir.



**Grafik 4.40.** ISBI2015 Verisetinin iMask R-CNN-RX101-D Eğitim Sürecin DSC Değişim Grafiği

ISBI2015 verisetinin iMask R-CNN-RX101-D testlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.27’de görülmektedir. Bu tabloya göre iMask R-CNN-RX101-D modeli ile DSC skoru %90.90 ve LTPR oranı %91.18 büyük başarıyla otomatik lezyon bölütleme yapılmıştır. Ayrıca LFPR oranı %2.62 ile çok düşük hatalı lezyon

seçimi yapılmıştır. iMask R-CNN-RX101-D ile yapılan testlerde ISBI2015 verisetinin MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür.

**Tablo 4.27.** ISBI2015 Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%90.90	%85.51	%14.48	%91.18	%2.62	%95.11	%89.65	0.1695	7.9340	0.7172

Başarıyla tespit edilen lezyon örnekleri Şekil 4.43’te görülmektedir. Şekilde her sırada aynı MR görüntüsünün önce uzman hekimlerin belirlediği lezyonlar işaretlenmiş versiyonu ardından sistem tarafından lezyon bölgesi olarak belirlenen alanlar görülmektedir.


#### 4.9.1. ISBI2015 Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi

ISBI2015 veriseti üzerinde yapılan testlerde elde edilen sonuçlar Tablo 4.28’da detaylı olarak listelenmiştir. En başarılı sonuçlar koyu olarak öne çıkarılmıştır. Sonuçlar incelendiğinde; Mask R-CNN mimarisindeki modellerin U-Net’e göre etkin bir başarıyı sağladığı görülmektedir. Tez kapsamında geliştirilen ve farklı yapılar ile testleri yapılan iMask R-CNN modelinin lezyon tespitini konusunda başarımın arttırılmasını sağladığı açıkça fark edilmektedir. iMask R-CNN-RX101-D modelinin her açıdan üstün başarı sağladığı testler de U-Net modeli belirlediği lezyonların doğru olması konusunda başarılı iken hata oranının da çok yüksek olduğu gözlenmiştir.

**Tablo 4.28.** ISBI2015 Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu

Model	DSC%	VOE(%)	ASD	HD95	AVD	LTPR(%)	LFPR(%)
U-Net	78.93	33.09	1.9569	10.9092	0.1731	<b>93.34</b>	14.07
Mask R-CNN-R101-K	86.91	18.94	4.4903	18.8129	0.3158	87.23	10.36
iMask R-CNN-R101-K	86.61	19.51	5.0420	19.3556	0.3445	89.43	10.92
iMask R-CNN-R101-D	89.44	16.70	0.8329	8.6711	0.1726	89.67	4.11
<b>iMask R-CNN-RX101-D</b>	<b>90.90</b>	<b>14.48</b>	<b>0.7172</b>	<b>7.9340</b>	<b>0.1695</b>	91.18	<b>2.62</b>

(a) Uzman Seçimi (Ground Truth) (b) Tahmin ile Uzman Seçiminin Örtüşmesi




Şekil 4.43. ISBI2015 Verisetinde iMask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

#### 4.10. MICCAI2008 Veriseti ile Yapılan Testler ve Elde Edilen Sonular

Tez alıřması kapsamında 11. Uluslararası Tıbbi Grnt Hesaplama ve Bilgisayar Destekli Mdahale Konferansı kapsamında dzenlenen yarıřma veriseti MICCAI2008 zerinde U-Net, Mask R-CNN-R101-K, iMask R-CNN-R101-K, iMask R-CNN-R101-D, iMask R-CNN-RX101-D derin ğrenme modellerinde eğitim ve testler gerekleřtirilmiřtir. Bu blmde MICCAI2008 veriseti ile yapılan tm eğitim ve test srelerinin detayları ve bařarılı rnek MR grselleri sunulmuřtur.


##### 4.10.1. MICCAI2008 Verisetinde U-Net ile Testler ve Elde Edilen Sonular

MICCAI2008 veriseti zerinde U-Net ile yapılan eğitimlerde veri arttırma katsayısı 4, lm aralık arpanı 1 olarak belirlenmiřtir. Bu oranlar zerinde 434 eğitim ve 131 test grntsnden oluřan veriseti 2216 eğitim ve 870 test verisine ıkarılmıřtır. Her grntden ortalama 8 farklı versiyon retilmiřtir. řekil 4.44'te MICCAI2008 verisetinde veri arttırma iřlemi uygulanarak elde edilmiř MR grntlerine rnekler sunulmuřtur.




řekil 4.44. MICCAI2008 Verisetinin Veri Arttırma Sonucu retilen MR ve Lezyon Maskeler

Arttırılmıř veriler zerinde 100 tur eğitim gerekleřtirilmiř ve her turda ağırlıklar kaydedilmiřtir. Eğitimin test verileri bu ağırlıklar zerinden hesaplanmıřtır. Grafik 4.41'de MICCAI2008 verisetinin U-Net ile eğitimi srecinde hata deęiřim grafięi grlmektedir. Burada eğitim srecinin bařarıyla tamamlandıęı grlmektedir.



**Grafik 4.41.** MICCAI2008 Verisetinin U-Net Eğitim Sürecinde Hata Değişim Grafiği

MICCAI2008 veriseti üzerinde U-Net ile eğitim ve test çalışmaları başarıyla tamamlanmıştır. Grafik 4.42’de yapılan eğitimler sonucunda elde edilen ağırlıkların test veriseti üzerindeki DSC’nin değişimi görülmektedir. Grafiğe göre; otomatik lezyon tespiti sürecinde MICCAI2008 verisetinden ayrılan test verileri için U-Net modeli ile kararlı bir sonuç çizgisi sergilemiştir. Ancak başarımın yüksek olmadığı da görülmektedir.



**Grafik 4.42.** MICCAI2008 Veriseti ile U-Net Üzerinde Yapılan Testlerinin DSC Değişiminin Grafiği

MICCAI2008 veriseti üzerinde U-Net eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.29’da görülmektedir. Bu tablo incelendiğinde %66.21 DSC skoru ve %75.38 LFPR oranı ile lezyon alanlarının ve lezyonların tespitinin başarımının düşük olduğu görülmektedir. Ayrıca %41.23 LFPR ile modelin hata oranının çok yüksek olduğu açıkça görülmektedir.


**Tablo 4.29.** MICCAI2008 Verisetinin U-Net ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%66.21	%51.25	%48.74	%75.38	%41.23	%71.50	%65.77	0.4713	29.5875	7.5578

Şekil 4.45'te her görüntünün üstünde sırasıyla (a) orijinal MR görüntüsü, (b) uzman hekimlerin belirlediği lezyon alanları, (c) U-Net modelinin belirlediği lezyon alanları üstte verilmiş, bu görüntülerin altında (d) orijinal MR ve uzman görüşü (sarı renkli alanlar) ile sistem tahmini (kırmızı renkli alanlar) sonuçlarının örtüşmesi verilmiştir.


#### 4.10.1. MICCAI2008 Verisetinde Mask R-CNN-R101-K ile Elde Edilen Sonuçlar

MICCAI2008 verisetinin Mask R-CNN-R101-K modeli ile yapılan eğitim süreci Grafik 4.43'te görülmektedir. Eğitim sürecinde genel hata değişiminin çok hızlı olduğu grafik incelendiğinde anlaşılmaktadır.




**Grafik 4.43.** MICCAI2008 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği

Mask R-CNN-R101-K ile yapılan eğitim 100 tur tekrarlanmış ve her turda bir ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.44'te görüldüğü gibidir. Verisetinin eğitim sürecindeki zorlukları test sürecine de yansımıştır ve grafik incelendiğinde testlerin kararsızlığı görülmektedir. En başarılı tur eğitiminin son turlarında alınan ağırlıklar arasından biri (97.) olmuştur.



**Şekil 4.45.** MICCAI2008 Verisetinde U-Net ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş Görüntüler, (a)Orijinal MR Görüntüsü, (b)Uzman Hekimlerin Belirlediği Lezyon Alanları, (c)U-Net Modelinin Belirlediği Lezyon Alanları, (d)MR ve Uzman Görüşü (Sarı Renkli Alanlar) ile Sistem Tahmini (Kırmızı Renkli Alanlar) Sonuçlarının Örtüşmesi



**Grafik 4.44.** MICCAI2008 Verisetinin Mask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi

Mask R-CNN-R101-K eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.30’da verilmiştir. Tablo incelendiğinde %82.07 DSC oranı ile otomatik lezyon alanlarının tespitinin sağlandığı görülmüştür.

**Tablo 4.30.** MICCAI2008 Verisetinin Mask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları


DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%82.07	%72.83	%27.16	%81.08	%10.79	%89.63	%80.58	0.3353	41.5897	6.6201

Yapılan testlerde Mask R-CNN-R101-K ile eHealth veriseti üzerinde önemli başarımlar sağlandığı görülmüştür. Şekil 4.46’da Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir.






#### 4.10.2. MICCAI2008 Veriseti ile iMask R-CNN-R101-K ile Elde Edilen Sonuçlar

MICCAI2008 verisetinin iMask R-CNN-R101-K ile yapılan eğitim sürecinin hata değişimleri Grafik 4.45’te görülmektedir. Genel hata oranındaki hızlı düşüş ve maskeleme hata ile doğru orantıda azalması eğitim sürecinin başarıyla tamamlandığını göstermektedir.


(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi




Şekil 4.46. MICCAI2008 Veriseti Üzerinde Mask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntülerine Örnekler



**Grafik 4.45.** MICCAI2008 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinin Grafiği

iMask R-CNN-R101-K ile yapılan eğitim 100 tur tekrarlanmış ve her turda bir ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde DSC'nin değişimi Grafik 4.46'da görüldüğü gibidir. Eğitimin ilk turlarından sonra DSC başarımının belli bir kararlılıkla seyrettiği grafik incelendiğinde görülmektedir.



**Grafik 4.46.** MICCAI2008 Verisetinin iMask R-CNN-R101-K ile Yapılan Eğitim Sürecinde Elde Edilen Ağırlıkların DSC Benzerlik Katsayısı Değişimi

iMask R-CNN-R101-K eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.31'de verilmiştir. Tabloda görülen DSC %80.73 ve LTPR oranının %81.43 olarak tespit edilmesi ile iMask R-CNN-R101-K ile MICCAI2008 veriseti üzerinde önemli başarımlar sağlandığı anlaşılmıştır.


**Tablo 4.31.** MICCAI2008 Verisetinin iMask R-CNN-R101-K ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%80.73	%70.95	%29.04	%81.43	%11.68	%87.06	%80.96	0.4185	45.8968	7.7041

Şekil 4.47’de Şekilde her görüntüde orijinal MR görüntüsünün üzerine, (a) uzman hekimlerin belirlediği lezyonlar ve (b) aynı görüntülerin orijinal MR görüntüsünün üzerine sistem tarafından lezyon bölgesi olarak belirlenen alanların örtüşmeleri görülmektedir.


#### 4.10.3. MICCAI2008 Veriseti ile iMask R-CNN-R101-D ile Elde Edilen Sonuçlar

MICCAI2008 verisetinin iMask R-CNN-R101-D modeli ile yapılan eğitim sürecinin hata değişimleri Grafik 4.47’de görülmektedir. Grafik incelendiğinde eğitim sürecindeki genel hatanın düşük bir noktadan başladığı ve hızla sıfıra doğru ilerlediği görülmektedir.




**Grafik 4.47.** MICCAI2008 Verisetinin iMask R-CNN-R101-D ile Yapılan Eğitim Sürecinin Grafiği

Yapılan eğitim sürecinde her 1000 iterasyonda bir periyot noktası belirlenmiş ve ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde oluşan DSC değişimi Grafik 4.48’de görüldüğü gibidir. Grafik incelendiğinde; testlerin kararlılıkla yakın sonuçlar verdiği görülmektedir.








**Grafik 4.48.** MICCAI2008 Verisetinin iMask R-CNN-R101-D Eğitim Sürecin DSC Değişimi

(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.47. MICCAI2008 Verisetinde iMask R-CNN-R101-K ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

MICCAI2008 verisetinde iMask R-CNN-R101-D eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.32’de görülmektedir. Bu tabloda DSC skorunun %83.88 ve LTPR oranının %84.37 olarak belirlenmiş ve iMask R-CNN-R101-D ile yapılan testlerde MICCAI2008 verisetinin MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür.


**Tablo 4.32.** MICCAI2008 Verisetinin iMask R-CNN-R101-D ile Alınan En İyi Tur Sonuçları

DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%83.88	%75.24	%24.76	%84.37	%8.36	%88.89	%82.89	0.2356	26.3907	4.0591

Başarıyla tespit edilen lezyon örnekleri Şekil 4.48’de görülmektedir. Şekilde her sırada aynı MR görüntüsünün önce uzman hekimlerin belirlediği lezyonlar işaretlenmiş versiyonu ardından sistem tarafından lezyon bölgesi olarak belirlenen alanlar görülmektedir. Lezyon alanlarının önemli oranda belirlendiği şekil incelendiğinde açıkça görülmektedir.


#### 4.10.4. MICCAI2008 Veriseti ile iMask R-CNN-RX101-D ile Elde Edilen Sonuçlar

MICCAI2008 verisetinin iMask R-CNN-RX101-D modeli ile yapılan eğitim sürecinin hata değişimleri Grafik 4.49’da görülmektedir. Eğitim sürecinde genel hatanın düşük bir oran ile başlayarak hızla sıfıra yaklaştığı grafikte görülmektedir.








**Grafik 4.49.** MICCAI2008 Verisetinin iMask R-CNN-RX101-D ile Yapılan Eğitim Sürecinin Grafiği

(a) Uzman Seçimi (Ground Truth)




(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.48. MICCAI2008 Verisetinde iMask R-CNN-R101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

Yapılan eğitim sürecinde her 1000 iterasyonda bir periyot noktası belirlenmiş ve ağırlık kaydı yapılmıştır. Bu ağırlıklar ile test seti üzerinde yapılan incelemelerde oluşan DSC değişimi Grafik 4.50’de görüldüğü gibidir. Grafik incelendiğinde, test sonuçlarının genel olarak yakın olduğu ve sistemin kararlılıkla çalıştığı anlaşılmaktadır.



**Grafik 4.50.** MICCAI2008 Verisetinin iMask R-CNN-RX101-D Eğitim Sürecin DSC Değişim Grafiği


iMask R-CNN-RX101-D eğitimlerinde DSC bakımından en iyi tur sonucunda elde edilen metrik skorları Tablo 4.33’te görülmektedir. En iyi tur sonuçlarına göre elde edilen %83.48 DSC ve %80.38 LTPR oranları önemli bir başarımla lezyon alanların otomatik olarak bölümlendiğini %4.58 LFPR oranı da hata oranının düşüklüğünü göstermektedir. Sonuç olarak iMask R-CNN-RX101-D ile yapılan testlerde MICCAI2008 verisetinin MS lezyonlarının başarıyla tespitinin sağlandığı görülmüştür

**Tablo 4.33.** MICCAI2008 Verisetinin iMask R-CNN-RX101-D ile Alınan En İyi Tur Sonuçları






DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
%83.48	%74.81	%25.19	%80.38	%4.58	%93.91	%78.63	0.2689	32.199	2.4606

Başarıyla tespit edilen lezyon örnekleri Şekil 4.49’da görülmektedir. Şekilde her sırada aynı MR görüntüsünün önce uzman hekimlerin belirlediği lezyonlar işaretlenmiş versiyonu ardından sistem tarafından lezyon bölgesi olarak belirlenen alanlar görülmektedir. Örnekler incelendiğinde lezyon örtüşme başarımları açıkça görülmektedir.

(a) Uzman Seçimi (Ground Truth)



(b) Tahmin ile Uzman Seçiminin Örtüşmesi



Şekil 4.49. MICCAI2008 Verisetinde iMask Mask R-CNN-RX101-D ile Yapılan Testlerde Başarıyla MS Lezyonu Tespit Edilmiş MR Görüntüleri

#### 4.10.5. MICCAI2008 Veriseti Üzerindeki Eğitim ve Testlerin Değerlendirmesi

MICCAI2008 veriseti üzerinde yapılan testlerde elde edilen sonuçlar Tablo 4.34'te detaylı olarak listelenmiştir. En başarılı sonuçlar koyu olarak öne çıkarılmıştır. Sonuçlar incelendiğinde iMask R-CNN modelinin önemli başarı sergilediği gözlenmiştir. U-Net modeli doğru lezyon belirleme açısından öne çıkmıştır. Detectron2 platformunda çalışan ResNet101 kullanan iMask R-CNN-R101-D modelinin ve ResNeXt101 kullanan iMask R-CNN-RX101-D modelinin genel izlenimde en başarılı yapı olduğu gözlenmiştir.

**Tablo 4.34.** MICCAI2008 Veriseti Üzerinde Yapılan Testlerin Karşılaştırma Tablosu

Model	DSC%	VOE(%)	ASD	HD95	AVD	LTPR(%)	LFPR(%)
U-Net	59.39	56.09	7.3975	30.4732	0.4073	<b>87.62</b>	18.67
Mask R-CNN-R101-K	82.07	27.16	6.6201	41.5897	0.3353	81.08	10.79
iMask R-CNN-R101-K	80.73	29.04	7.7041	45.8968	0.4185	81.43	11.68
<b>iMask R-CNN-R101-D</b>	<b>83.88</b>	<b>24.76</b>	4.0591	<b>26.3907</b>	<b>0.2356</b>	84.37	8.36
iMask R-CNN-RX101-D	83.48	25.19	<b>2.4606</b>	32.1990	0.2689	80.38	<b>4.58</b>

#### 4.11. MS Lezyonlarının Tespit Sürecinde Kullanılan Modellerin Karşılaştırmalı Değerlendirmesi

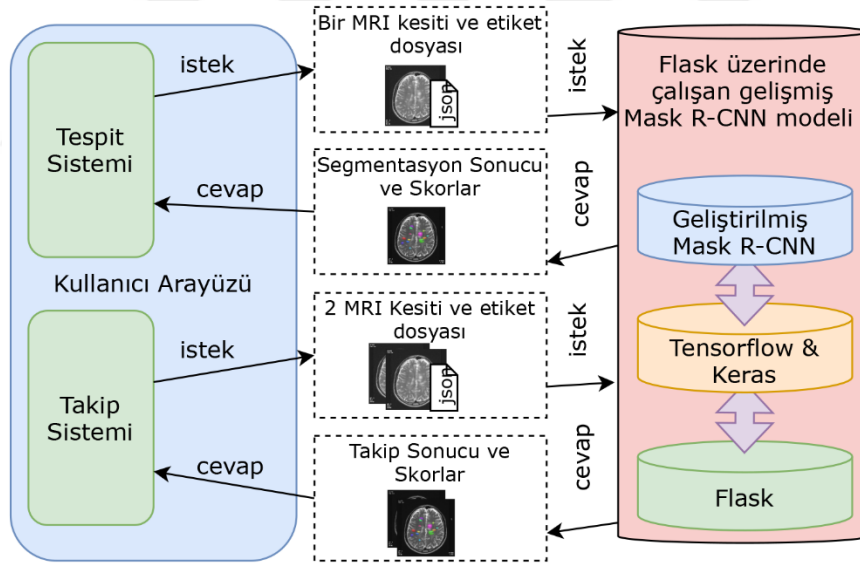
Tez kapsamında yapılan çalışmalarda bir açık veriseti ve dört açık veriseti ile 5 farklı derin öğrenme modeli üzerinde eğitimler ve testler gerçekleştirilmiştir. Yapılan eğitim ve test süreçlerinin detayları bölümün önceki kısımlarında sunulmuştur. Tablo 4.35'te tüm modellerde verisetleri üzerinde elde edilen test sonuçları detayları ile sunulmuştur. Kendi verisetleri içinde en başarılı skorlar koyu ile gösterilmiştir. Bu tablo incelendiğinde, iMask R-CNN-RX101-D isimli Detectron2 ortamında kullanılan ResNeXt101 omurga yapısına sahip iMask R-CNN modelinin en az 3 metrik açısından bütün verisetlerinde en başarılı model olduğu görülmektedir. LFPR ve PRE metriği incelendiğinde iMask R-CNN-RX101-D modelinin tüm modellere göre üstünlüğü görülmektedir. DSC incelendiğinde iMask R-CNN-RX101-D ve iMask R-CNN-R101-D tüm verisetlerinde en başarılı sonuca ulaşmıştır ve UMCL veriseti üzerinde bu açıdan en yüksek başarımla lezyon tespiti sağlandığı görülmüştür. Mask R-CNN-R101-K modelinin bazı yönlerden öne çıktığı görülmüştür ve iMask R-CNN-R101-K modelinin LTPR oranlarında tüm verisetlerinde öne çıktığı görülmektedir. Diğer metriklerde modeller arasında küçük farklılıklar olduğu tabloda gözlenmektedir.

**Tablo 4.35.** Modellerin Karşılaştırma Tablosu

Model	Veriseti	DSC	JSC	VOE	LTPR	LFPR	PRE	RC	AVD	HD95	ASD
U-Net	MSAkdeniz	%82.55	%71.56	%28.43	%92.01	%12.76	%85.98	%81.16	0.168	15.808	3.568
	eHealth	%65.29	%50.49	%49.51	%86.91	%13.39	%66.23	%70.53	0.419	39.717	9.354
	UMCL	%79.42	%69.38	%30.10	%83.68	%21.26	%86.18	%77.25	0.164	28.575	4.723
	ISBI2015	%78.93	%66.90	%33.09	<b>%93.34</b>	%14.07	%81.99	%78.91	0.173	10.909	1.957
	MICCAI2008	%66.21	%51.25	%48.74	%75.38	%41.23	%71.50	%65.77	0.471	29.588	7.558
Mask R-CNN-R101-K	MSAkdeniz	%83.64	<b>%75.98</b>	<b>%24.01</b>	%84.58	%12.79	%87.34	%84.03	0.291	23.292	4.231
	eHealth	%79.02	%68.40	%31.59	%82.00	%22.01	%77.39	%81.67	0.648	44.895	11.456
	UMCL	%82.35	%72.61	%27.39	%80.42	%7.98	%91.25	%78.34	0.340	21.537	3.198
	ISBI2015	%86.91	%81.06	%18.94	%87.23	%10.36	%90.74	%86.71	0.316	18.813	4.490
	MICCAI2008	%82.07	%72.83	%27.16	%81.08	%10.79	%89.63	%80.58	0.335	41.590	6.620
iMask R-CNN-R101-K	MSAkdeniz	%81.97	%74.12	%25.88	%85.39	%15.13	%83.47	%85.05	0.257	22.107	4.640
	eHealth	%84.59	%76.25	%23.75	<b>%90.80</b>	%15.71	%83.51	<b>%90.71</b>	0.574	37.347	9.121
	UMCL	%84.84	%75.75	%24.25	%86.14	%9.79	%89.43	%83.53	0.368	17.513	3.471
	ISBI2015	%86.61	%80.48	%19.51	%89.43	%10.92	%87.98	%89.17	0.345	19.356	5.042
	MICCAI2008	%80.73	%70.95	%29.04	%81.43	%11.68	%87.06	%80.96	0.419	45.897	7.704
iMask R-CNN-R101-D	MSAkdeniz	%83.47	%71.50	%28.49	%90.77	%6.63	%89.47	%89.08	0.160	8.109	1.552
	eHealth	%86.47	%78.97	%21.02	%86.87	%8.69	%90.26	%86.56	0.365	29.971	4.157
	UMCL	<b>%92.24</b>	<b>%86.90</b>	<b>%13.10</b>	<b>%92.45</b>	%3.27	%94.19	<b>%91.31</b>	0.072	<b>1.767</b>	<b>0.236</b>
	ISBI2015	%89.44	%83.29	%16.70	%89.67	%4.11	%94.52	%88.17	0.173	8.671	0.833
	MICCAI2008	<b>%83.88</b>	<b>%75.24</b>	<b>%24.76</b>	<b>%84.37</b>	%8.36	%88.89	<b>%82.89</b>	<b>0.236</b>	<b>26.391</b>	<b>4.059</b>
iMask R-CNN-RX101-D	MSAkdeniz	<b>%85.59</b>	%75.03	%24.97	<b>%92.01</b>	<b>%4.60</b>	<b>%92.14</b>	<b>%91.46</b>	<b>0.115</b>	<b>4.505</b>	<b>0.823</b>
	eHealth	<b>%89.00</b>	<b>%82.54</b>	<b>%17.45</b>	%86.86	<b>%4.89</b>	<b>%94.32</b>	%86.81	<b>0.320</b>	<b>24.315</b>	<b>2.723</b>
	UMCL	%91.70	%85.97	%14.03	%91.08	<b>%3.14</b>	<b>%94.77</b>	%90.01	<b>0.066</b>	1.910	0.290
	ISBI2015	<b>%90.90</b>	<b>%85.51</b>	<b>%14.48</b>	%91.18	<b>%2.62</b>	<b>%95.11</b>	<b>%89.65</b>	<b>0.170</b>	<b>7.934</b>	<b>0.717</b>
	MICCAI2008	%83.48	%74.81	%25.19	%80.38	<b>%4.58</b>	<b>%93.91</b>	%78.63	0.269	32.199	2.461

## 5. MS LEZYONLARINDAKİ DEĞİŞİMİN TAKİBİ İÇİN DERİN ÖĞRENME TABANLI BİR KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİ

Tez çalışması kapsamında, MR görüntüleri üzerinde MS lezyonlarının tespiti ve değişiminin takibi için Keras ortamında ResNet101 omurga yapısını kullanan iMask R-CNN (iMask RCNN-R101-K) derin öğrenme modeli kullanılarak bir bilgisayarlı karar destek sistemi (KDS) geliştirilmiştir. Geliştirilen KDS bir web uygulaması olarak planlanmış ve DeepMSWeb kısaltması ile isimlendirilmiştir. Şekil 5.1’de DeepMSWeb mimarisinin açık blok diyagramı görülmektedir. Blok diyagram da görülen mavi alan kullanıcı arayüzünü, kırmızı alan ise sunucudaki işlemleri temsil etmektedir. Kullanıcıdan gelen isteğin içeriğine göre sunucu cevap göndermektedir. Kullanıcı sadece tek MR kesiti üzerinde istekte bulunduğu tespit sistemi, iki MR kesiti üzerinde çalışmak istediğinde değişimin takibi sistemi devreye girmektedir. Ayrıca kullanıcı istekte bulunurken MR kesitleri içindeki lezyon alanlarını belirten uzman görüşü dosyasını da eklerse sistem uzman görüşleri ile otomatik tespit sonuçlarının karşılaştırmasını da raporlamaktadır.



**Şekil 5.1.** MS Lezyonlarının Tespiti İçin Önerilen DeepMSWeb Mimarisinin Açık Blok Diyagramı


Bölümün ilerleyen kısımlarında DeepMSWeb mimarisi, uygulamanın geliştirilmesinde kullanılan derin öğrenme ortamı, uygulama ortamı olan Flask Framework’u ve diğer araçların detaylarından bahsedilmiştir.

## 5.1. Materyal ve Yöntem

DeepMSWeb mimarisinde kullanılan bileşenler MS veriseti, kullanılan derin öğrenme modeli ve ortamı, geliştirilen web platformunun alt yapısı ve arayüz tasarım öğelerinden oluşmaktadır. DeepMSWeb web uygulaması içerisinde kullanılan Tensorflow 2.0 çatısı ve Keras API'sisinden oluşan derin öğrenme modeli iMask R-CNN, Flask çatısının içerisine gömülmüştür. Uygulama aktifleştirildiğinde tüm alt uygulamalar otomatik yüklenerek çalışma ortamı hazır hale gelmektedir. Web uygulaması içerisinde bilgilerin uygun bir şekilde transferi için *request* ve *Jinja2* kullanılmaktadır. Web uygulamasının ön yüz tasarımında Bootstrap kütüphanesi kullanılarak hazırlanan HTML, CSS ve JQuery tabanlı kalıplardan yararlanılmıştır. Bu sayede hazırlanan kullanıcı arayüzü bilgisayar, tablet ve mobil cihazlara uygun hale getirilmiştir. Ayrıca, sonuçların gösterildiği sayfalarda görüntülerin tam ekran görüntülenebilmesi için GLightBox javascript kütüphanesi kullanılmıştır.

### 5.1.1. eHealth Veriseti

Önerilen KDS yapısında, öncelikle iMask RCNN-R101-K modeli ile eğitim aşaması önceden tamamlanmış ve en iyi ağırlık dosyası alınmıştır. Bu eğitimde ve uygulama örneğinde tezin önceki bölümlerinde detayları sunulan olan eHealth veriseti kullanılmıştır. Bu veriseti hastaların periyodik muayene görüntülerini barındırdığı için MS lezyonlarının takip edilebilmesine uygundur. Şekil 5.2'de eHealth verisetinden aynı hastanın periyodik muayenesinde alınan MR çekimlerinden bazı örnek kesitler gösterilmiştir. Çalışma kapsamında eğitim kümesinde 398 ve test kümesinde 121 görüntü kullanılmıştır. Ayrıca, test verilerinden periyodik çekimlere göre sekiz örnek grup oluşturulmuştur.



**Şekil 5.2.** eHealth Verisetinden Aynı Hastanın (a) İlk MR Çekiminden, (b) İkinci Muayenedeki MR Çekiminden Alınan Bazı Örnek Kesitler

### **5.1.2. Derin Öğrenme Ortamı ve Model**

MS lezyonlarının tespiti ve takibi için önerilen web tabanlı KDS'nin derin öğrenme ortamında, web uygulamaları için kullanımı daha pratik ve hızlı olduğu için Keras alt yapısı kullanılmıştır. Ayrıca yapılan eğitim ve test işlemleri için tez kapsamında önerilen iMask R-CNN modeli kullanılmıştır. Tablo 4.1'de özellikleri sunulan bilgisayar üzerinde açıklanan eğitim ve test süreçleri sonucunda %84.59 DSC başarımına sahip ağırlıklar sistemin değerlendirilmesinde kullanılmıştır.

### **5.1.3. Flask Çatısı**

DeepMSWeb uygulaması üzerinde MS lezyonlarının tespiti ve takibi için kullanılan iMask R-CNN modelinin web tabanlı uyarlaması Flask çatı uygulaması üzerinde uygulanmıştır. Flask, Python dilinde çalışan ve web uygulamaları için geliştirilmiş bir mikro-çatı uygulamasıdır (Grinberg, 2018: 1). Werkzeug ve Jinja2 tabanlı BSD-3-Clause lisanslı Python dilini kullanan çok küçük boyutlu bir çatı yapısıdır. Flask küçük boyutlu olmasına rağmen, işlevsel oldukça geniş uygulamaları desteklemektedir. Bunun yanında, Flask oldukça basit olmasının yanında gerektiğinde genişletilebilir bir çerçevedir (Relan, 2019: 1). Bir Flask uygulamasının başlangıç yapısından yararlanarak uygulama geliştirmeye başlamak ve yönlendirme işlemi kolaydır.

### **5.1.4. Arayüz Araçları**


Geliştirilen web uygulamasının ön yüz tasarımında, HTML'de (Hypertext Markup Language, Hiper Metin İşaretleme Dili) hazırlanmış bir kalıp dosyası kullanılmıştır. Bu kalıbın düzenlenmesinde CSS (Cascading Style Sheets, Basamaklı Stil Şablonları) betikleri ve Bootstrap kütüphanesinden faydalanılmıştır. Bootstrap kütüphanesi ile DeepMSWeb'in farklı ekran boyutlarında otomatik organize edilmesi sağlanmıştır. Bu sayede farklı ekran boyutlarındaki mobil cihazlar, tabletler ve bilgisayarlar ile tam uyumlu çalışma imkânı sağlanmıştır. Ayrıca, DeepMSWeb'te sayfa üzerindeki etkileşimi gerçekleştirmek için JQuery ve GLightBox javascript kütüphaneleri kullanılmıştır. Bu kütüphaneler ile sayfanın farklı ekran boyutlarına göre organizasyonu ve sonuç gösteriminde görüntülerin tam ekran görüntülenebilmesi sağlanmıştır.

### **5.1.5. Örtüşme Tespit Algoritması**

MR görüntülerinin edinimi sırasında hastanın bulunduğu pozisyon gereği, görüntülerde açısız farklılıklar meydana gelebilmektedir. Bu nedenle DeepMSWeb uygulamasında, MR

taramaları üzerinde deęişimin tespiti ařamasında kesitlerde belirlenen MS lezyonları üzerinde bir Örtüşme Tespit Algoritması (ÖTA) geliştirilmiştir. Bu algoritma ile MS lezyonlarındaki deęişimleri takip etmek için farklı periyotlarda, birbirine benzeyen lezyonların doęru tespit gerçekleştirilmiştir. DeepMSWeb sisteminde lezyon alanlarını birbiri ile eşleřtirmek için Şekil 5.3'te görülen ÖTA verilen ile lezyonlar arasında hacimsel farklılıklar deęerlendirilmektedir. Burada, hacimsel benzerlikleri en fazla olan lezyonlar temel alınarak, sistem tarafından lezyonlar sıralı olarak tespit edilmektedir ve karşılaştırılmaktadır.

ÖTA'da otomatik tespit edilen lezyonlarda sistem üzerinde hata olabileceęi için %2 gibi bir eşik deęeri belirlenmiştir. Belirlenen eşik deęerinden fazla hacimsel küçülme olursa; eşik deęerinin altında deęişim olan lezyon maskeleri küçülmüş, eşik deęerinin üstünde olan lezyon maskeleri ise büyümüş olarak kabul edilmektedir. Bu oran aynı zamanda iMask R-CNN derin öğrenme mimarisi için de başarımlı eşik olarak belirlenmiştir. Böylece, iMask R-CNN ile eşik deęerinin altındaki benzerliklerin önemsiz olduęu kabul edilmiştir. ÖTA'da aynı zamanda, örtüşen lezyon maskelerinde  $\pm$  eşik deęerinin altında deęişim olan lezyonlar deęişmemiş kabul edilmektedir. Bunun yanında, iki MR kesiti üzerinde yapılan incelemede en az bir lezyon maskesinde örtüşme olmazsa sistem uyumsuz kesitler olduęuna karar vermektedir



**Şekil 5.3.** DeepMSWeb ile MS Lezyonlarındaki Deęişim Tespitinin İncelenmesi Sırasında İncelenen İki MR Kesitinin Örtüşmesini Deęerlendiren ÖTA Yapısı

DeepMSWeb lezyon tespiti ve deęişimin takibi sistemi örtüşme skorları temelinde çalışmaktadır. Skorların ölçülmesi için geliştirilen ÖTA'nın sözde kodları Tablo 5.1'de

görüldüğü gibidir. Algoritma gönderilen maske dizilerinin içinde sırayla gezerek tüm kesişmelerin hesaplamasını yapmaktadır. Öncelikle maske matrislerine normalizasyon işlemini uygulayarak matrislerin değişimlerini hesaplamaktadır. İlişki kurulamayan lezyonların bu işlem sonucunda değişim skorları sıfır (0)'a çekilmektedir.

**Tablo 5.1.** Lezyon Karşılaştırmasında Skorları Belirleyen Algoritmanın Psudo Kodu

```
procedure Karsilastir(masks1,masks2)
```

```
Input:
```

```
mask1: ilk MR çekiminin maskelerini barındıran matris  $a \times b \times C$  boyutunda
```

```
mask2: ikinci MR çekiminin maskelerini barındıran matris  $a \times b \times D$  boyutunda
```

```
Output:
```

```
skor: tüm lezyonların karşılaştırma CXD boyutlu
```

```
for each mask1 in masks1 (i=1 to C):
```

```
mask1Norm=mask1/sqrt(sum(mask1**2))
```

```
for each mask2 in masks2 (t=1 to D)::
```

```
mask2Norm=mask2/sqrt(sum(mask2**2))
```

```
skor[i,t]=sum(mask1Norm*mask2Norm)
```

```
If not iliskiVarmi(mask1,mask2):
```

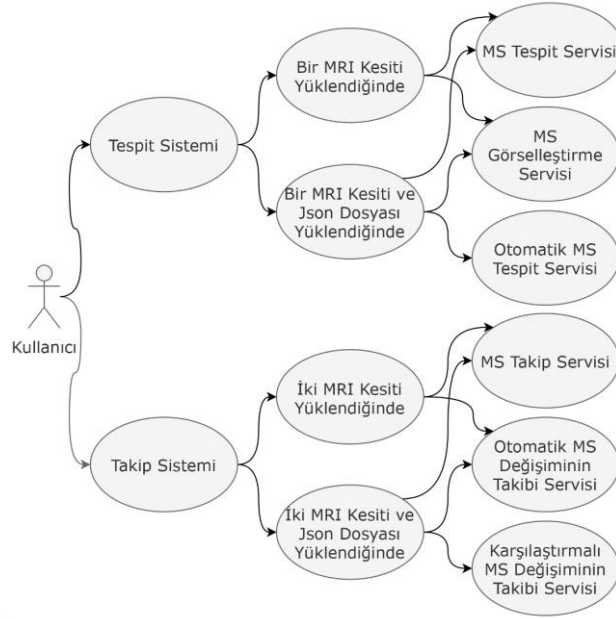
```
skor=0
```

```
end procedure
```

## 5.2. DeepMSWeb KDS'nin Alt Yapısı

DeepMSWeb esnek ve zengin içeriklere sahip bir kullanıcı arayüzü ile desteklenmiş MS lezyonlarını tespit sistemi ile MS lezyonlarındaki değişimin belirlenmesini sağlayan takip sistemi olmak üzere iki ana yapıdan oluşmaktadır. Uygulama Flask çatısı üzerinde yerleştirilmiş bir Mask R-CNN derin öğrenme modelinin birleşmesinden meydana gelmektedir. Bu iki altyapı kendi arasında istek-cevap iletişimi ile bağlantı kurmaktadır. Tespit ve takip sisteminde lezyon tanımlaması yapılacak bir MR görüntüsü Flask üzerindeki Mask R-CNN modeline aktarılmaktadır. Bu aşamada sistem tarafından gerekli incelemeler yapıldıktan sonra kullanıcı arayüzüne lezyonların bölütlenmiş görüntüleri, örtüşme dosyaları ve benzerlik skorları cevap olarak gönderilmektedir.

DeepMSWeb web uygulaması altı servis içermektedir. Bunlar MS görüntüleme, MS tespiti ve otomatik MS tespiti, MS takibi, otomatik MS takibi ve karşılaştırmalı MS takip servisleridir. Bu servisler kullanıcıdan alınan MR görüntüsü ve VGG 1.0.6 formatındaki uzman görüşlerini içeren dosya ile çalışmaktadır. Bu servisler tespit sistemi ve takip sistemi altında kullanıcıdan alınan geri dönüşlere göre işlem yapmaktadır. Şekil 5.4'te geliştirilen DeepMSWeb uygulamasının kullanıcı durum diyagramı görülmektedir.



Şekil 5.4. DeepMSWeb Uygulamasının Kullanıcı Durum Diyagramı

### 5.3. DeepMSWeb KDS Kullanılarak MS Lezyonlarının Tespiti Sistemi

Bu tez çalışması kapsamında, MS lezyonlarının otomatik tespiti için geliştirilen DeepMSWeb web uygulamanın karşılama/anasayfası Şekil 5.5'te görülmektedir. Bu sayfadan DeepMSWeb aracılığıyla MS lezyonlarının tespiti ve değişimi yapılan uygulamalara geçiş yapılmaktadır.



Şekil 5.5. MS Lezyonlarının Otomatik Tespiti İçin Bu Çalışmada Geliştirilen DeepMSWeb Web Uygulamanın Karşılama/Anasayfası

### 5.3.1. Tespit İçin Veri Giriş Formu

MS kesitlerindeki lezyonların otomatik tespiti sisteminin çalışması için anasayfadaki “Uygulamalar” linkinden “MS Lezyonlarının Otomatik Tespiti” kısmına girildiğinde kullanıcının incelemek istediği MR görüntüsünün ve görüntüye ait uzman maskesini barındıran .json dosyasının Şekil 5.6’daki sayfadan yüklenmesi gerekmektedir.

Şekil 5.6’da görülen forma uygun formatta MR görüntüsü yüklendiğinde formun alt kısmındaki ön izleme alanında yüklenen MR görüntüsü kullanıcıya sunulmaktadır. Bu sayede sistem çalıştırılmadan önce görüntünün incelenmesi ve doğruluğu kullanıcı tarafından yapılabilmektedir. Şekil 5.7’de ön izleme görüntüsü yüklenmiş form sayfası görülmektedir.

The screenshot shows the 'Otomatik MS Tespiti' (Automatic MS Detection) page on the DeepMSWeb application. The page has a dark green header with the logo and navigation links: Ana Sayfa, Multipl Skleroz, Servisler, Örnekler, Proje Ekibimiz, Yayınlar, Uygulamalar, and İletişim. The main content area has a light green background with the title 'Otomatik MS Tespiti' and a brief description: 'MR görüntülerindeki MS plaklarını otomatik olarak algılayan ve bunları uzman hekim görüşü ile karşılaştıran bu uygulama sayfası. Bunun için MR görüntülerinin bölütleme bilgilerini VGG 1.0.6 formatında yüklemelisiniz.' Below this, there are two example sets, 'Örnek Set 1' and 'Örnek Set 2'. There is a dropdown menu for selecting an MR slice, a file upload field for the expert mask, and a green button labeled 'MS Lezyonlarını Tespit Et'. Below the button, there is a preview area for the uploaded MR slice and its result, labeled 'Yüklenen MR Kesiti' and 'UPLOADED IMAGE RESULT'.

Şekil 5.6. DeepMSWeb Üzerinde MS Lezyonlarının Otomatik Tespiti İçin MR Kesitini ve Uzman Maskesi Dosyasını Yükleme Sayfası

## Otomatik MS Tespiti

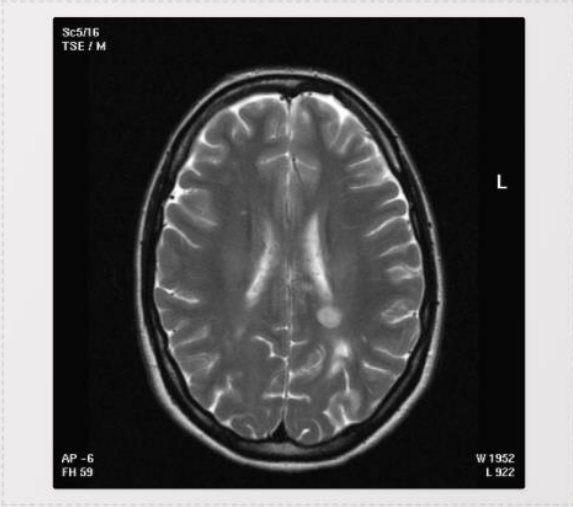
Örnek Set 1      Örnek Set 2

MRI Kesiti : AA\_first\_IM\_00038.jpg

Uzmanın etiketlerini içeren dosyayı yükleyin

**MS Lezyonlarını Tespit Et**

Yüklenen MR Kesiti



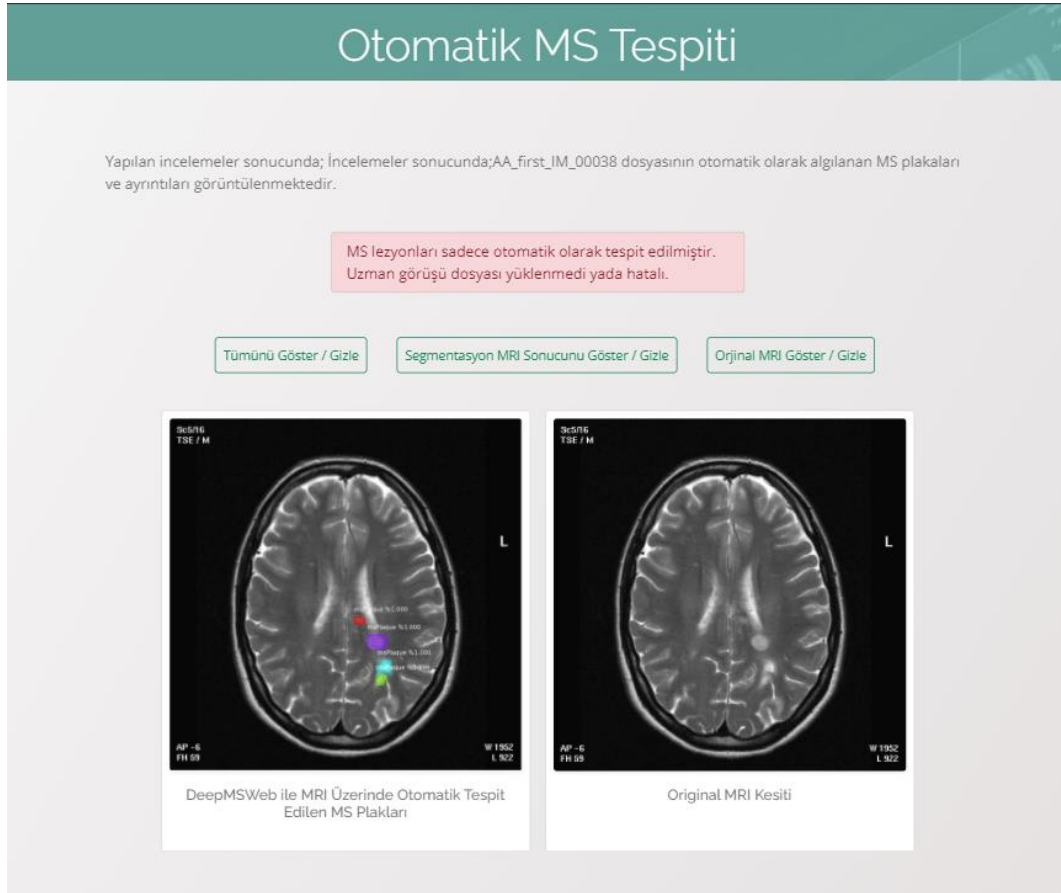
**Şekil 5.7.** DeepMSWeb Üzerinde MS Lezyonlarının Otomatik Tespiti İçin MR Kesitini ve Uzman Görüşü Dosyasını Yükleme Sayfasının Ön İzleme Yapan Hali

### 5.3.1. MS Lezyonları Tespit Sisteminin Sonuçlarının Gösterimi

Şekil 5.6'daki forma sadece MR görüntüsü yüklenerek veya MR ve uzman maskesi dosyası beraber yüklenerek 2 farklı şekilde çalışması sağlanabilmektedir. Sadece MR görüntüsü yüklendiğinde sistem tarafından otomatik tespit edilen MS lezyonları Şekil 5.8'deki gibi görüntülenmektedir. Bu ekranda orijinal MR kesitinin yanında otomatik belirlenen MS lezyonları da görülmektedir.

Şekil 5.7'deki form sayfasına hem MR kesiti hem de uzman maskesi dosyası yüklendiğinde Şekil 5.9'da görülen sonuç ekranı ile sonuçlar raporlanmaktadır. Bu ekran 3 alt parçadan oluşmaktadır. Şekil 5.9(a)'da DeepMSWeb sistemi tarafından otomatik belirlenen lezyonlar ile uzman görüşü arasındaki karşılaştırma sonucunda sistemin başarımleri görülmektedir. Şekil 5.9(b)'de ise, kullanıcı ara yüzündeki görüntülerin açılıp kapatılmasına yarayan kontrol alanı görülmektedir. Şekil 5.9(c)'de sırasıyla orijinal MR kesiti, uzman

maskesinin orijinal MR kesiti üzerine işlenmiş hali, otomatik tespit edilmiş lezyonların MR kesiti üzerine işlenmiş hali ve uzman maskesi ve otomatik tespit edilmiş lezyonların MR kesiti üzerine işlenmiş halini içeren görsel bloğu içermektedir.



Şekil 5.8. DeepMSWeb'e Sadece MR Kesiti Yüklendiği Zaman Görülen Sonuç Sayfası

### 5.3.1. DeepMSWeb KDS ile MS Lezyonu Tespit Örnekleri

DeepMSWeb üzerinden yapılan otomatik tespit işlemlerinin uzman görüşleri ile karşılaştırmalı sonuçları ve sistemin verdiği sonuçlar Şekil 5.10'da görülmektedir. Burada, otomatik tespit sonucu olarak sistemin sunduğu görseller ile uzman seçimlerinin örtüşmeleri görülmektedir. Otomatik tespit sisteminin skorları incelendiğinde DSC %81.93 ve %87.60 oranları ile önemli bir ölçüde lezyon tespiti sağlanmıştır. Ayrıca %100 LTPR oranıyla MR kesitleri üzerindeki tüm MS lezyon alanlarının başarıyla tespit edildiği görülmektedir. Sistemin çıktısı olan görseller ve sonuç metrikleri incelendiğinde tespit sisteminin başarımı açıkça görülmektedir.

## Otomatik MS Tespiti

Yapılan incelemeler sonucunda; AA\_first\_IM\_00038 dosyasında incelemeler sonucunda; otomatik olarak algılanan MS plak(lar)ının tüm detayları görülmektedir.

(a)

Değerlendirme ölçütlerine göre tespit başarımları skorları	
Ölçüt	Skor
DC	%87.60
VOE	%22.07
LTPR	%100.00
LFPR	%0.00

(b)

Tümünü  
Göster / Gizle


Segmentasyon MRI  
Sonucunu Göster / Gizle

GT - Segmentasyon MRI  
Örtüşmesi Göster / Gizle


GT MRI  
Göster / Gizle

Orjinal MRI  
Göster / Gizle


(c)




DeepMSWeb ile MRI Üzerinde Otomatik Tespit Edilen MS Plakları



MRI Üzerinde Otomatik Tespit Edilen MS Plakları ve Uzman Seçimlerinin Örtüşmesi



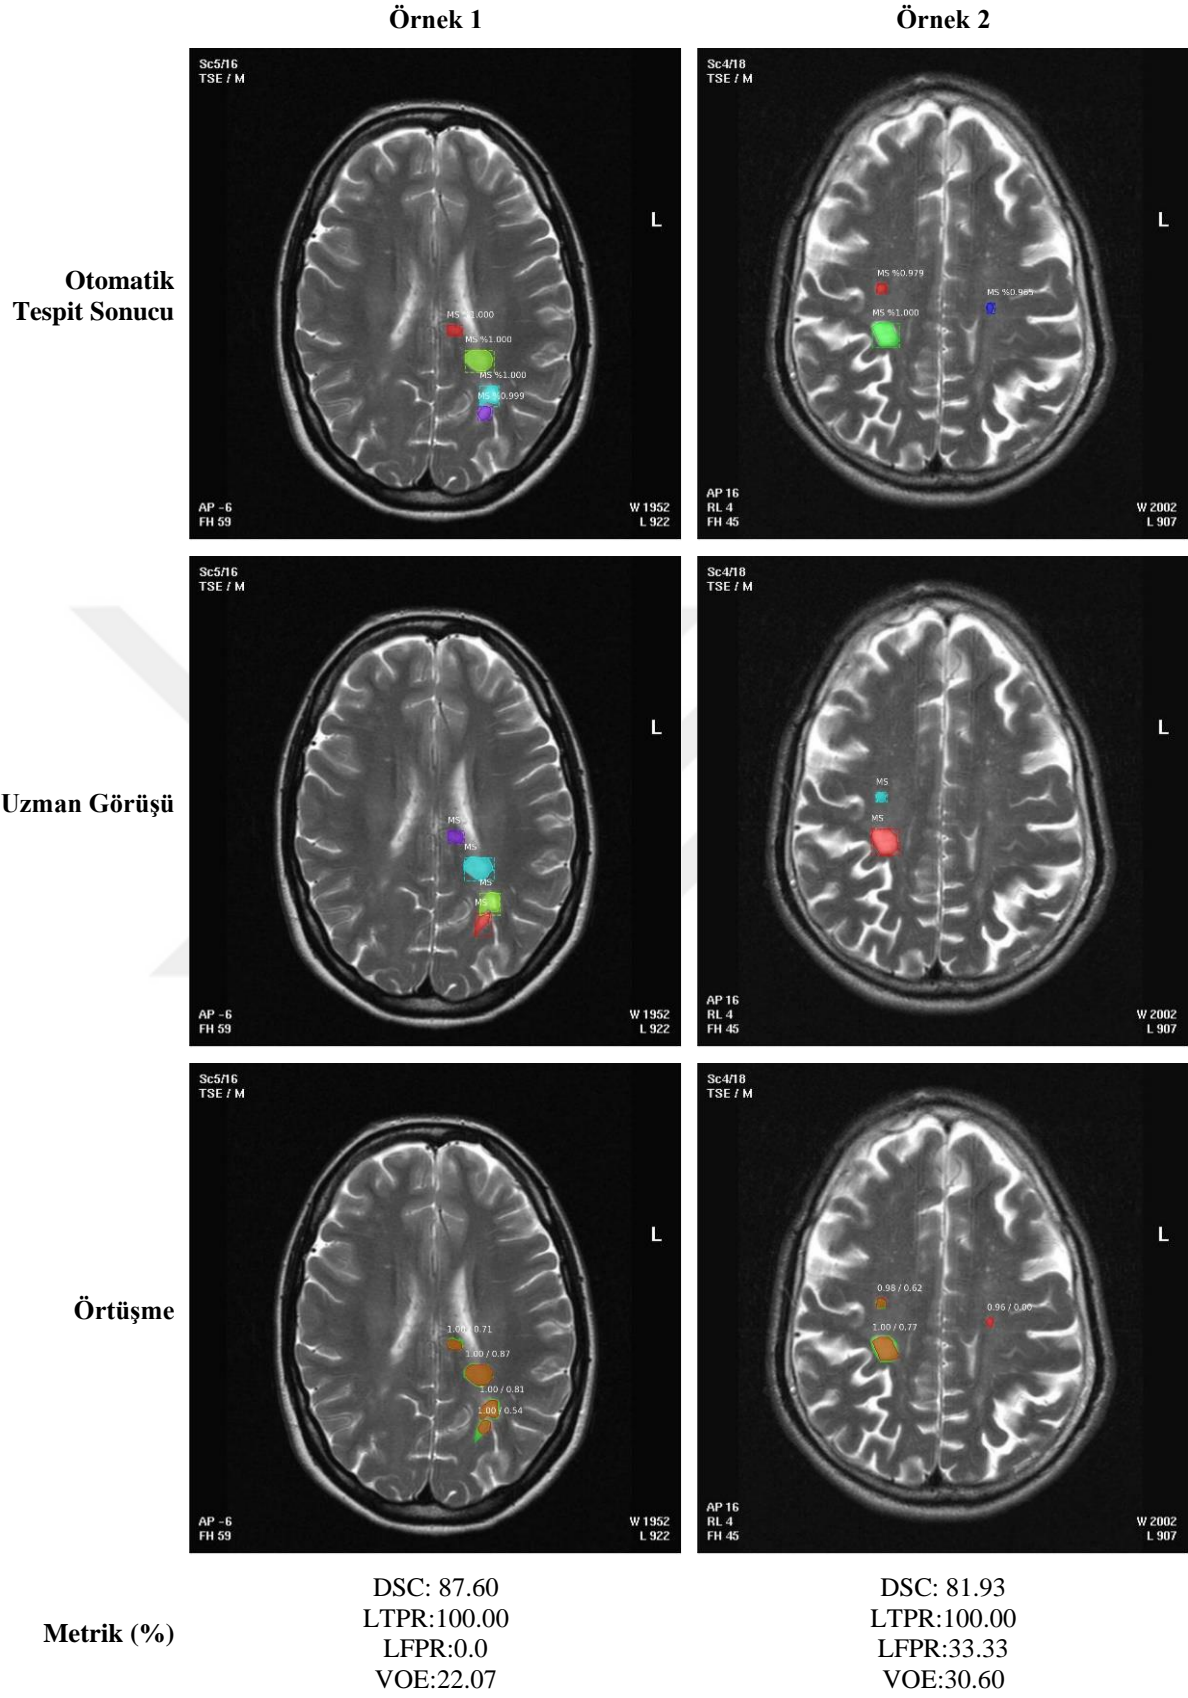
Uzman Görüşlerini İçeren MRI Kesiti (GT)



Original MRI Kesiti



**Şekil 5.9.** DeepMSWeb Kullanılarak MR Görüntüleri Üzerinde MS Lezyonlarının Otomatik Tespiti ve Sonuçların Karşılaştırılması



Şekil 5.10. DeepMSWeb Üzerinden KDS'nin Tespit Sisteminin Sonuç Örnekleri

## 5.4. DeepMSWeb KDS Kullanılarak MS Lezyonlarının Değişimin Takibi Sistemi

DeepMSWeb uygulaması ile bu aşamada iki farklı periyotta alınan birbirine yakın MR kesitleri üzerinde çeşitli incelemeler yapılmaktadır ve değişimler belirlenerek kullanıcıya sunulmaktadır. MS lezyonlarındaki otomatik değişim tespiti sisteminin çalışması için ana sayfadaki “Uygulamalar” linkinden “MS Lezyonlarının Otomatik Takibi” kısmına tıkladığında bu sistem devreye girmektedir.

### 5.4.1. Takip Sisteminin Veri Giriş Formu

Takip sisteminde öncelikle, kullanıcının incelemek istediği MR görüntülerini ve görüntülere ait uzman görüşü barındıran json dosyasının Şekil 5.11’deki sayfadan yüklenmesi gerekmektedir.

DeepMSWeb uygulamasının en önemli tanı-karar destek unsuru olan Takip Sistemi için iki farklı çalışma sistemi hazırlanmıştır. Değişimin takibi işleminde, her MS görüntüsü için otomatik tespit edilen MS lezyonları ve bu lezyonlar üzerinden belirlenen değişim tespiti sonuçları kullanıcıya sunulur. Şekil 5.11’deki form ekranına MR kesitleri yüklendiğinde görülen ön izleme ekranı Şekil 5.12’deki gibidir.

Karşılaştırmalı Otomatik Değişim Tespiti

Hekimler tarafından işaretlenen MS plaklarının görüntülediği ve iki farklı dönemde çekilen görüntülerin karşılaştırıldığı uygulama sayfamızdır. Bunun için segmentasyon dosyanızı MR bölümünde ve VGG 1.0.6 formatında yüklemelisiniz.

Örnek Set 1 Örnek Set 2

İlk MR kesitini seçin İkinci MR kesitini seçin

Uzmanın etiketlerini içeren dosyayı yükleyin

MS Lezyonlarının Değişimini Tespit Et

İlk MR Kesiti İkinci MR Kesiti

UPLOADED IMAGE RESULT UPLOADED IMAGE RESULT

Şekil 5.11. DeepMSWeb Uygulamasında Takip Sistemine MR Görüntülerinin ve json Dosyalarının Yüklendiği Form Sayfası

## Karşılaştırmalı Otomatik Değişim Tespiti

Örnek Set 1Örnek Set 2

İlk MR Kesiti



İkinci MR Kesiti



**Şekil 5.12.** DeepMSWeb Uygulamasında Takip Sistemine MR Görüntülerinin ve json Dosyalarının Yüklendiği Form Sayfasının Ön İzleme Ekranı

#### 5.4.1. Takip Sisteminin Sonuçlarının Gösterimi

Şekil 5.13’de lezyonlardaki değişimi izleyen takip sisteminin sadece MR görüntüleri yüklenerek çalıştırıldığında elde edilen sonuç ekranları görülmektedir. Tespit edilen değişim sonuçlarında büyüme ve küçülme belirlenen lezyonların oranları ve sayıları ilk MR görüntüsünde görülürken, ikinci MR görüntüsünde görülmeyen veya tersi durumdaki lezyonların sayıları sunulmaktadır. Ayrıca bu detaylar güçlü renklendirme yapısı ile öne çıkarılmıştır.

Şekil 5.11’de görülen giriş formuna aynı hastanın farklı iki periyoddaki yakın kesitlerinden MR görüntüleri yüklenirse öncelikle sistem tarafından MS tespitleri gerçekleştirilmektedir. Tespit edilen MS lezyonlarının arasındaki ilişki Şekil 5.14 ve Şekil 5.15’deki gibi görüntülenmektedir. Bu ekranda, otomatik MS tespiti ve uzman görüşleri ile örtüşmelerin tespiti sunulmuştur. Buradan, hem otomatik tespit edilen lezyonların hem de uzman görüşlerinde belirtilen lezyonların değişimlerinin belirlenmesi görülebilir. Tespit edilen lezyonlar ile uzman görüşlerini karşılaştırarak MS tespitinin başarımları ile değerlendirmesini de bu aşamada yapılmaktadır. Otomatik tespit edilen lezyonlar arasındaki

değişim ve uzman görüşleri arasındaki değişim tespitleri ayrı ayrı belirlenerek kullanıcıya sunulmaktadır.

## Karşılaştırmalı Otomatik Değişim Tespiti

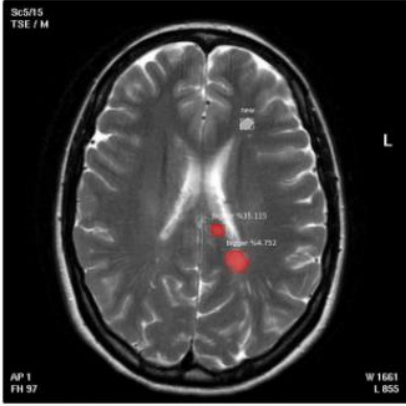
Yüklenen dosyaların sistem tarafından otomatik olarak algılanan plak(lar)ı ve bu plaklardaki değişikliklerin otomatik tespiti aşağıda detaylı olarak görülmektedir.

1 plakda %4.75 büyüme gözlenmiştir.
1 plakda %35.11 büyüme gözlenmiştir.
2 plakda büyüme gözlenmiştir.
2 plak gözlenmemiştir.
1 yeni plak(lar) tespit edildi.

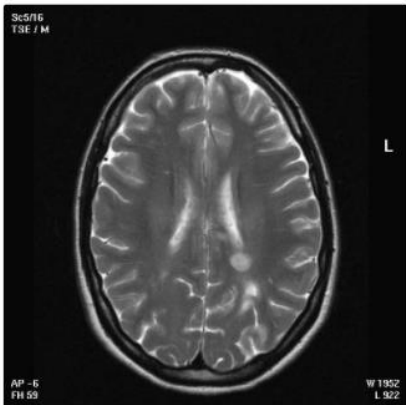
[Tümünü Göster / Gizle](#) [Segmentasyon MRI Sonucunu Göster / Gizle](#) [Orjinal MRI Göster / Gizle](#)



DeepMSWeb ile İlk MRI Üzerinde Otomatik Tespit Edilen MS Plakları



DeepMSWeb ile İkinci MRI Üzerinde Otomatik Tespit Edilen MS Plakları



Original İlk MRI Kesiti



Original İkinci MRI Kesiti

Şekil 5.13. Takip Sisteminde Otomatik Lezyon Tespiti İçin Sonuç Ekranı

## Karşılaştırmalı Otomatik Değişim Tespiti

Yükelenen dosyaların uzman hekim görüşleri ile belirtilen plak(lar) sistemin otomatik tespit ettiği plak(lar) ve bu plakların değişimlerinin otomatik tespiti, aşağıda detaylı olarak görülmektedir.

### DeepMSWeb'e Göre Değişim Bilgileri

1 plakda %4.75 büyüme gözlenmiştir.
1 plakda %35.11 büyüme gözlenmiştir.
2 plakda büyüme gözlenmiştir.
2 plak gözlenmemiştir.
1 yeni plak(lar) tespit edildi.

### Uzman Görüşlerine Göre Değişim Bilgileri

1 plakda %5.06 büyüme gözlenmiştir.
1 plakda %7.14 büyüme gözlenmiştir.
2 plakda büyüme gözlenmiştir.
2 plak gözlenmemiştir.
1 yeni plak(lar) tespit edildi.

### İlk MRI Tespit Skorları

Ölçüt	Skor
DC	%87.60
VOE	%22.07
LTPR	%100.00
LFPR	%0.00

### İkinci MRI Tespit Skorları

Ölçüt	Skor
DC	%92.78
VOE	%13.46
LTPR	%100.00
LFPR	%0.00


Tümünü Göster / Gizle

Segmentasyon MRI Sonucunu Göster / Gizle


GT - Segmentasyon MRI Örtüşmesi Göster / Gizle

GT MRI Göster / Gizle

Orjinal MRI Göster / Gizle

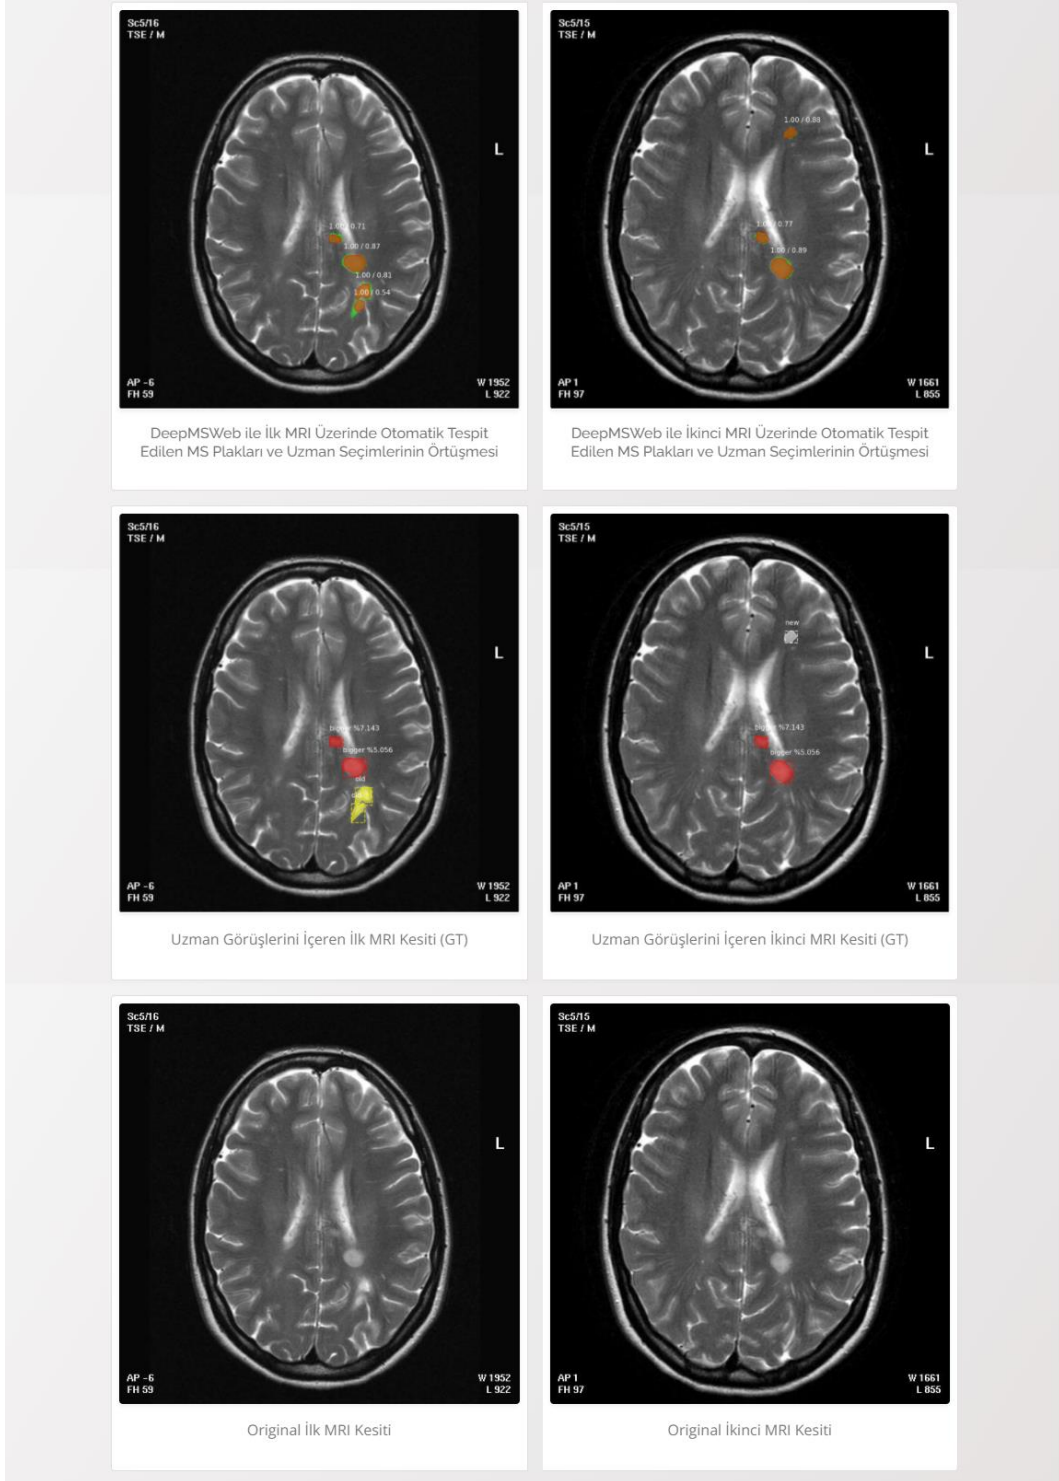


DeepMSWeb ile İlk MRI Üzerinde Otomatik Tespit Edilen MS Plakları



DeepMSWeb ile İkinci MRI Üzerinde Otomatik Tespit Edilen MS Plakları

**Şekil 5.14.** Takip Sisteminde Karşılaştırmalı Otomatik MS Lezyonu Tespit İçin Sonuç Ekranı (Birinci Bölüm)



**Şekil 5.15.** Takip Sisteminde Karşılaştırmalı Otomatik MS Lezyonu Tespit İçin Sonuç Ekranı (İkinci Bölüm)

#### 5.4.1. DeepMSWeb KDS ile MS Lezyon Takip Örneği

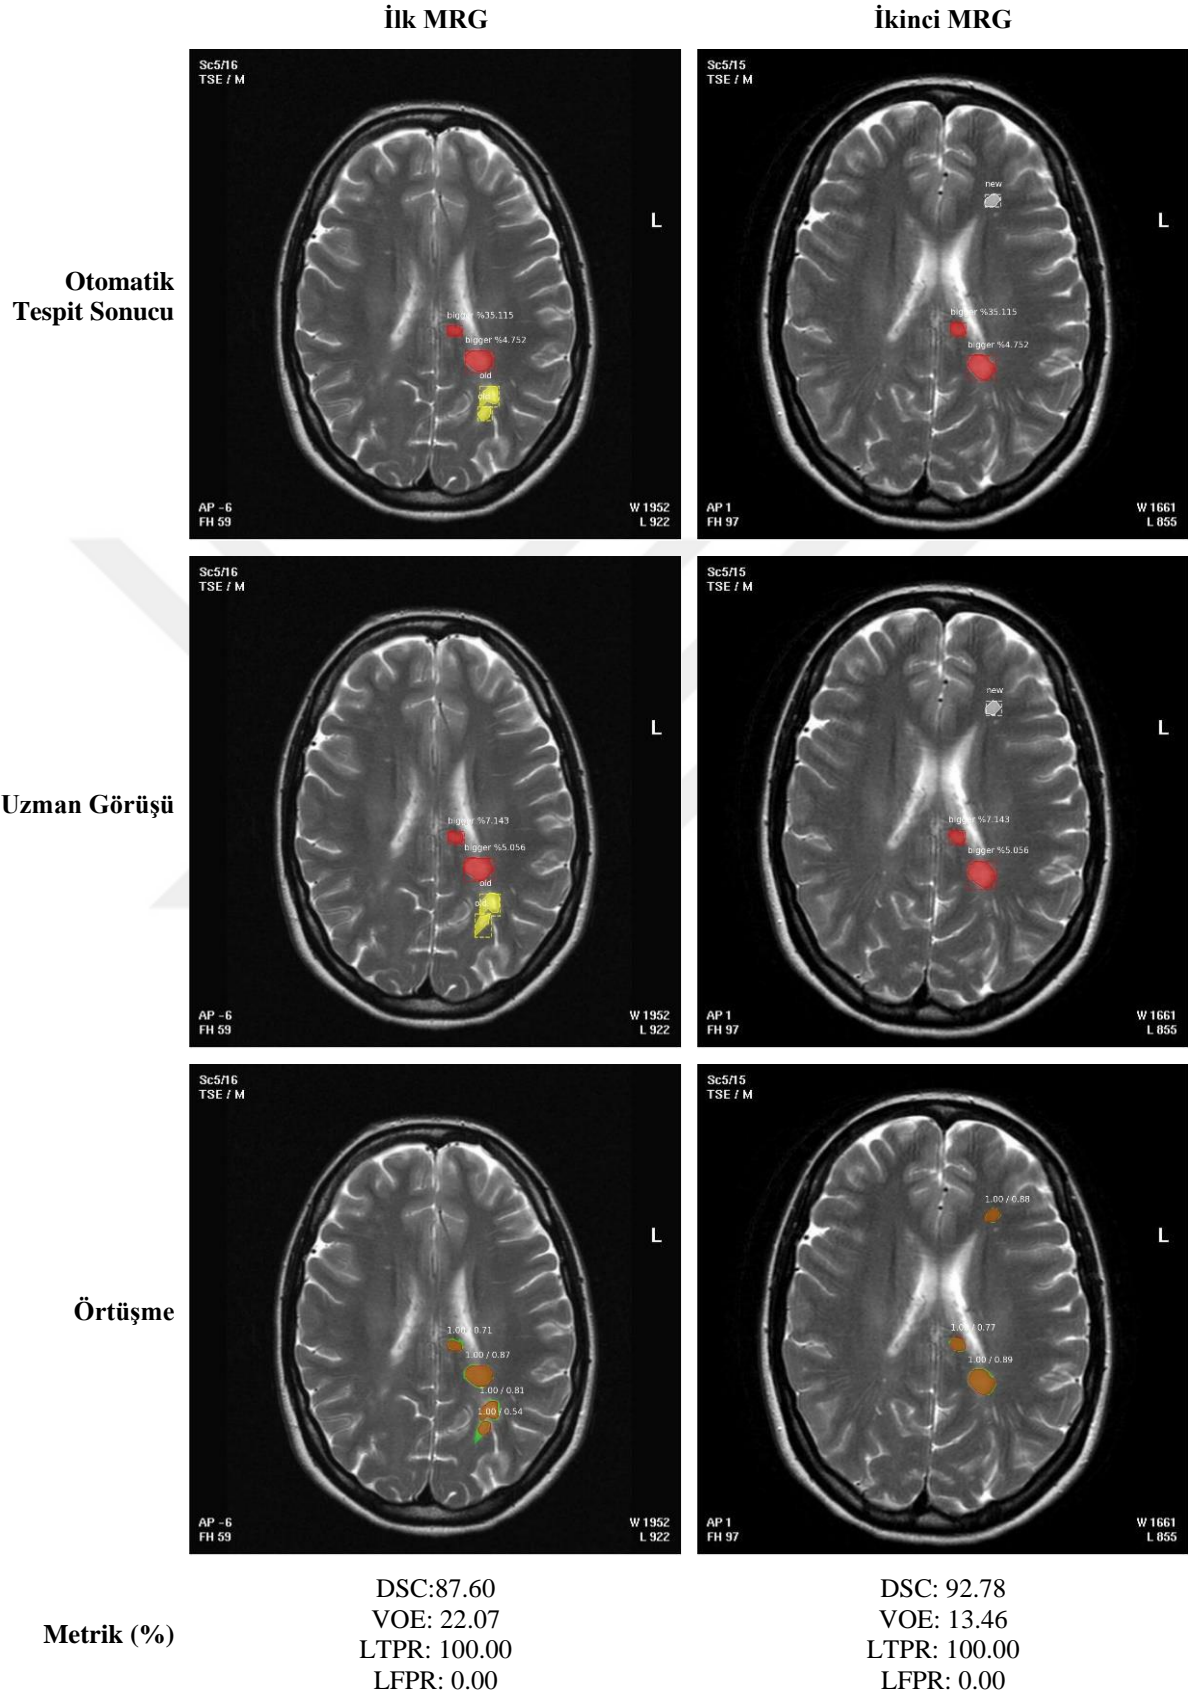
DeepMSWeb üzerinden yapılan otomatik takip işlemlerinin uzman görüşleri ile karşılaştırmalı sonuçlarının ve sistemin verdiği sonuçların örnekleri Şekil 5.13, Şekil 5.14 ve Şekil 5.15'te görülmektedir. DeepMSWeb otomatik takip sistemine gönderilmiş iki örnek MR

kesitinden ve uzman görüşlerini içeren json dosyasından oluşan takip setinin sonuç raporu Tablo 5.2’de görülmektedir. Bu raporda DeepMSWeb tarafından alınan sonuçlar ile uzman görüşleri karşılıklı olarak sunulmuştur. Rapor incelendiğinde tüm lezyonlarda sistemin uzman hekimler ile aynı sonuca ulaştığı görülmektedir. Değişim oranı olarak belirlenen skorlar yakın olmakla birlikte bir lezyonun değişim oranında büyük fark görülmektedir. Bu durum lezyon alanlarının küçük olmasından kaynaklıdır. Örnekte görüldüğü gibi, sistem kaybolan lezyonları, yeni oluşan lezyonları ve büyüyen lezyonları doğru olarak tespit etmiştir. DeepMSWeb KDS’nin lezyonlardaki otomatik değişim tespitini büyük başarı ile sağladığı buradan açıkça görülmektedir.

**Tablo 5.2.** DeepMSWeb-KDS’nin Takip Sistemi Sonuç Raporu Örneği

DeepMSWeb'e Göre Değişim Bilgileri	Uzman Görüşlerine Göre Değişim Bilgileri
1 plakda %4.75 büyüme gözlenmiştir.	1 plakda %5.06 büyüme gözlenmiştir.
1 plakda %35.11 büyüme gözlenmiştir.	1 plakda %7.14 büyüme gözlenmiştir.
2 plakda büyüme gözlenmiştir.	2 plakda büyüme gözlenmiştir.
2 plak gözlenmemiştir.	2 plak gözlenmemiştir.
1 yeni plak(lar) tespit edildi.	1 yeni plak(lar) tespit edildi.


DeepMSWeb tarafından üretilen görseller ve karşılaştırma sonuçları Şekil 5.16’da görülmektedir. Otomatik takip sisteminin skorları incelendiğinde DSC skorları %87.60 ve %92.78 oranları ile önemli bir ölçüde lezyon tespiti sağlanmıştır. Ayrıca %100 LTPR oranıyla MR kesitleri üzerindeki tüm MS lezyon alanlarının başarıyla tespit edildiği görülmektedir. Sistemin çıktısı olan görseller ve sonuç metrikleri incelendiğinde lezyon tespit ve takip sisteminin başarılı olduğu açıkça görülmektedir.



Şekil 5.16. DeepMSWeb Üzerinden KDS'nin Takip Sistemi Sonuç Örneği

## 5.5. DeepMSWeb Uygulamasının Özellikleri

DeepMSWeb uygulaması hekimlerin analizlerinde kolaylık sağlamak için çeşitli imkanlar sunmaktadır. Bu imkanlar, MR görüntülerini tam ekran olarak gösterme, tablet ve mobil cihazlarda tam verimlikle sunmak olarak sıralanabilir. Şekil 5.17’de MR görüntülerinin tam ekran görüntülenmesine bir örnek görülmektedir. Bu sayede uzmanlara sistemi kullanırken MR’ı tüm detayları ile inceleme fırsatı verilmektedir



Şekil 5.17. MR Görüntüsünün Tam Ekran Görünümü

Şekil 5.18’de takip sisteminin giriş form ekranının farklı mobil cihazlarda nasıl görüldüğünün örnekleri sunulmuştur. Şekilde form ekranının (a) cep telefonu ekranında görünümü, (b) tabletlerde görünümü görülmektedir.

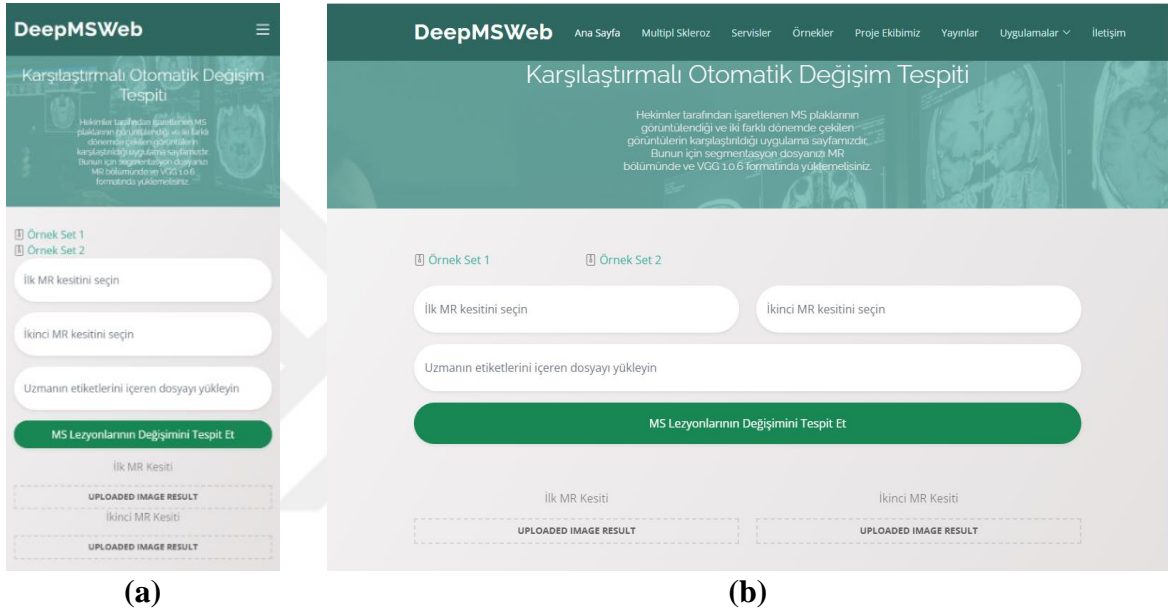
### 5.1. DeepMSWeb KDS’nin Değerlendirmesi

Bu tez çalışması kapsamında önerilen DeepMSWeb KDS’nin bir derin öğrenme modeli temelinde MS tespiti ve değişiminin takibi için hekimlere hizmet edebilecek bir ortam olması planlanmıştır. Çalışmalar sürecinde tez kapsamında geliştirilen iMask R-CNN derin öğrenme modelinin de bu uygulama üzerinde lezyon tespiti konusunda başarıyı değerlendirilmiştir.

DeepMSWeb uygulamasında lezyon tespit sisteminin başarıyla çalıştığı Şekil 5.8 Şekil 5.9 ve Şekil 5.10’da sunulan örneklerde görülmektedir. iMask R-CNN modeli başarıyla otomatik lezyon tespiti sağlamıştır. Ayrıca DeepMSWeb ile takip sistemi Şekil 5.13, Şekil 5.14, Şekil 5.15 ve Şekil 5.16’da sunulan örneklerde ki gibi başarıyla çalışmaktadır. ÖTA yapısı takip sisteminin önemli bir parçası olan tez çalışmaları kapsamında geliştirilmiş bir algoritmadır.

ÖTA ile lezyon değişimlerinin tespiti başarıyla çalıştığı örneklerde görülmektedir. ÖTA sayesinde aynı hastaya ait iki farklı periyotta alınan MR görüntülerinde bulunan lezyonlar ilişki ve hacimsel değişimler başarıyla tespit edilmiştir.

DeepMSWeb uygulaması geliştirilen arayüz içinde bulunan araçlar sayesinde bilgisayarların yanında cep telefonları ve tablet gibi mobil cihazlar ile de başarıyla kullanılabilir olarak tasarlanmıştır. Kullanıcılar farklı cihazlarda MR görüntülerini yükleyerek sonuçları inceleyebilmektedir. Ayrıca sonuçların görsellerini tam ekran olarak inceleme imkânı bulabilmektedir.



**Şekil 5.18.** DeepMSWeb Takip Sisteminin Farklı Ekran Boyutlarında Görünümü (a) Cep Telefonunda Görünüm, (b) Tablet Ortamında Görünüm

## 6. TARTIŞMA

Tez çalışması kapsamında, MS lezyonlarının derin öğrenme modelleri ile otomatik tespiti ve lezyonların farklı periyotlardaki değişiminin takibi gerçekleştirilmiştir. Literatür çalışmalarında, MS lezyonlarının boyutlarının genel olarak küçük olduğu evrelerde tespiti zor olduğu görüldüğünden, tez çalışmasında Mask R-CNN mimarisi kullanılarak daha küçük boyutlu lezyonların da tespiti için iyileştirilmiş bir yöntem (iMask R-CNN) önerilmiştir. Önerilen model iki farklı derin öğrenme platformunda kullanılarak beş farklı verisetinde deneysel çalışmalar yürütülmüştür.

Çalışmalar sırasında MS lezyonları ile ilgili çalışmalarda kullanılmak üzere yeni bir veriseti hazırlanmıştır. Geliştirilen verisetinin yanında 4 farklı açık veriseti de geliştirilen modelin başarımını test etmek için kullanılmıştır. Tüm eğitim ve test çalışmaları hazırlanan yeni veriseti ile beraber 5 farklı veriseti üzerinde 4 farklı derin öğrenme modeli ile 2 farklı platform üzerinde gerçekleştirilmiştir.

MS hastalığında hastalığın seyrinin takip edilmesinin büyük önem arz ettiği literatür incelemelerinde öne çıkan bir problemdir. Tez kapsamında geliştirilen web tabanlı derin öğrenme platformu ile MS lezyonlarının değişimin tespit edilmesi için bir plan ortaya konulmuştur.

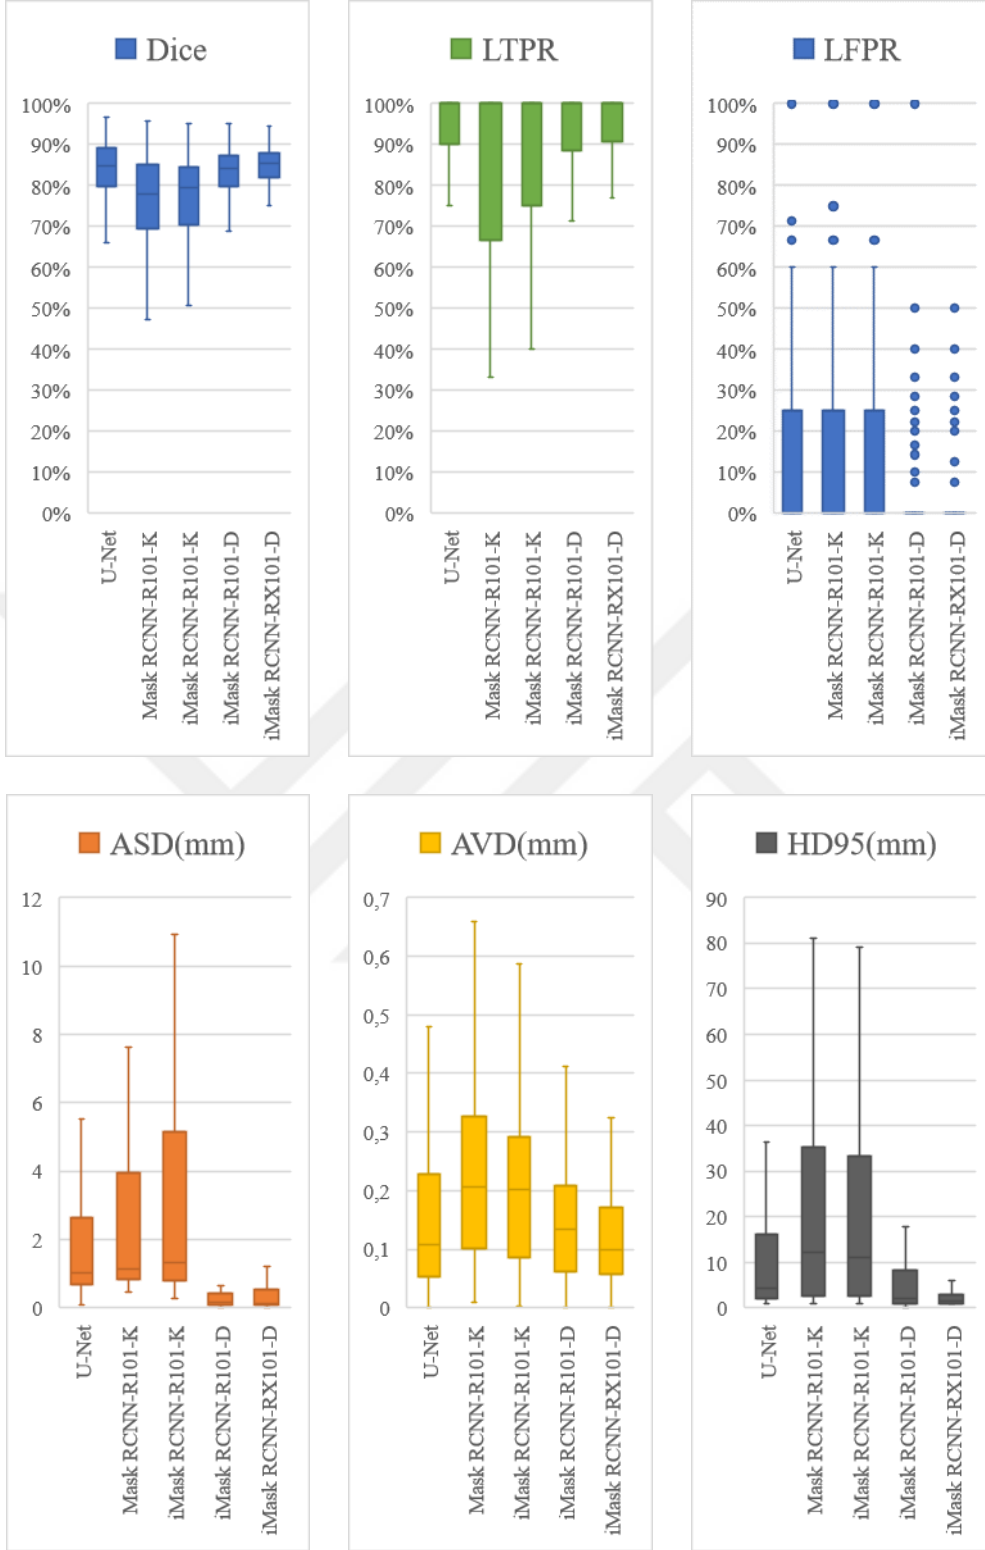
Önerilen derin öğrenme modeli olan iMask R-CNN ile beraber literatürde sıkça kullanılan U-Net ve Standart Mask R-CNN mimarileri ile Keras, Detectron2 platformlarında farklı omurga yapılarında eğitim ve testler uygulanmıştır. Ayrıca iMask R-CNN mimarisi ResNet101 ve ResNeXt101 omurga yapılarında uygulamaya sunulmuştur. Tez kapsamında hazırlanan MSAkdeniz veriseti ile beraber eHealth, UMCL, ISBI2015 ve MICCAI2008 verisetlerinde yapılan testler bu bölümde karşılaştırılmıştır.

Çalışma kapsamında hazırlanan MSAkdeniz verisetinin uzman hekimler tarafından etiketlenmesi devam etmektedir. Etiketlerin bilimsel çalışmalara uygun bir formatta hazırlanması, tamamlanan etiketlerin başka uzmanlar tarafından teyit edilmesi ilerleyen süreçte yeni çalışmalar ile tamamlanacaktır. Tez kapsamında bu verisetinin bir kısmı deneysel çalışmalar için hazırlanmıştır ve çalışmalar bu kısım üzerinden ayrılan veriler ile gerçekleştirilmiştir. MSAkdeniz veriseti MS hastalarının T2-FLAIR sekansında alınmış görüntülerini içermektedir. Tez çalışmasının 2. Bölümünde MS lezyonlarının hekimler tarafından izlenmesi konusunda detayları sunulduğu üzere T2-FLAIR sekanslı MR çekimleri

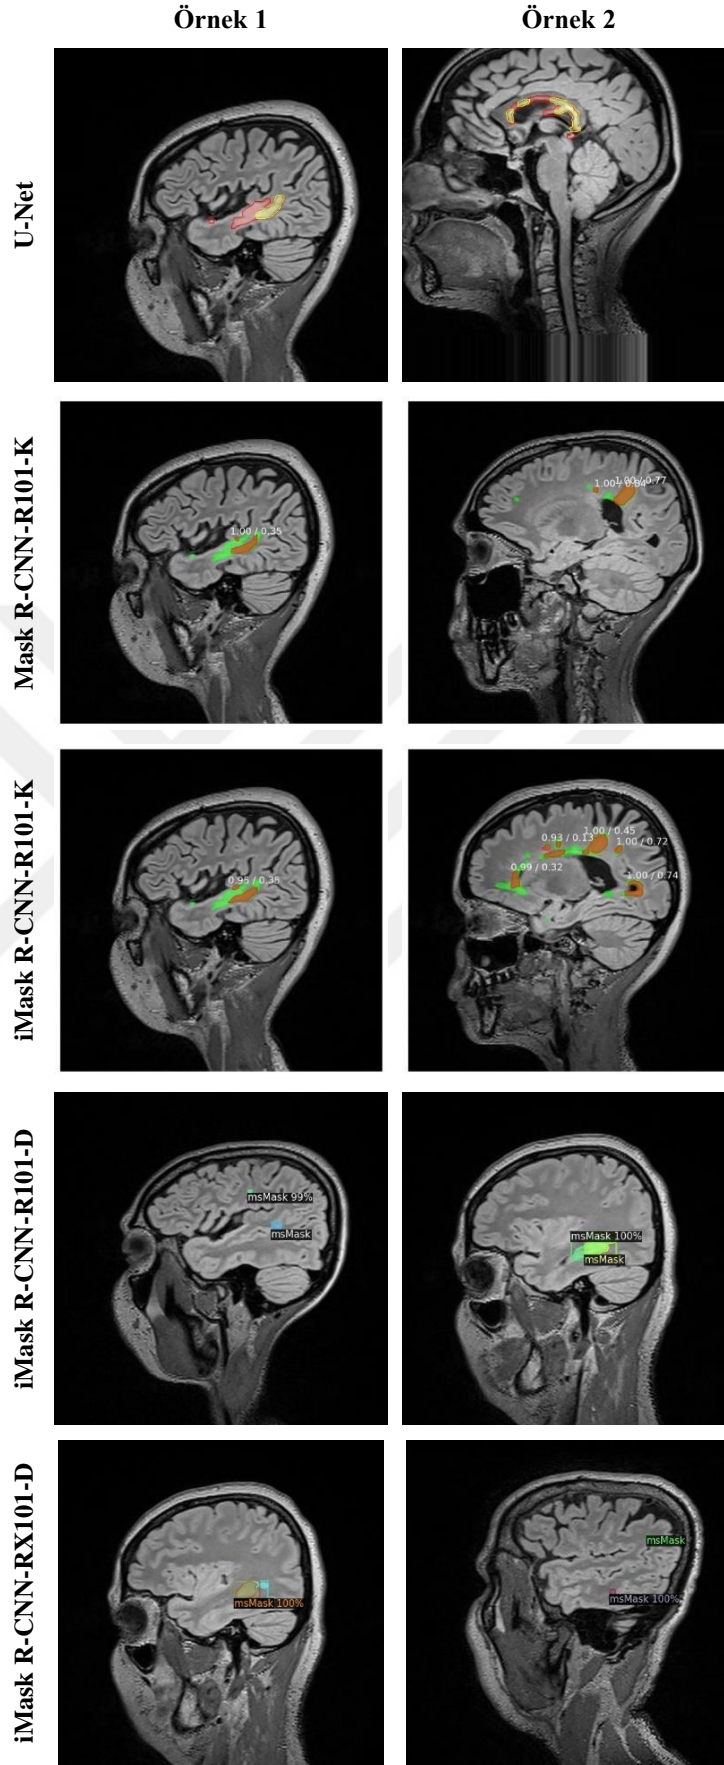
MS lezyonlarının tespitinde daha başarılı olduğu görülmektedir. Bu nedenle veriseti üzerinde %85.59 DSC benzerlik oranı ile etkili bir tespit başarımı sağlanmıştır.

Grafik 6.1’de farklı derin öğrenme modelleri için MSAkdeniz veriseti üzerinde yapılan eğitimler de elde edilen en iyi tur sonuçlarının test verisetleri için sonuçları kutu grafikleri ile gösterilmiştir. Grafik incelendiğinde modellerin tüm metriklerde değişimleri açıkça görülmektedir. Detectron2 platformundaki sonuçların Keras platformuna göre üstünlüğü ve başarısı ve ResNeXt101 omurga yapısını kullanan gelişmiş Mask R-CNN modelinin en başarılı model olduğu açıkça görülmektedir. U-Net modeli verisetinin tek tip olması nedeniyle etkili bir başarımlar elde etmiştir. iMask R-CNN modelinin lezyonların tespiti, görüntü üzerindeki lezyonların hacimsel ve nicel olarak tespiti, daha az hatalı lezyon tespiti ve lezyon olarak belirlenen alanlar sınırlarının doğruya yakınlığı açısından diğer modellere göre daha başarılı olduğu görülmektedir.

MSAkdeniz veriseti ile farklı derin modelleri ile yapılan deneysel çalışmalar sonucunda MS lezyonları başarıyla tespit edilememiş MR Görüntülerine örnekler Şekil 6.1’de görülmektedir. Şekil incelendiğinde; verisetinin yapısının önerilen modeller için bir zorluk içerdiği görülmüştür. Modellerin genel başarımlarıyla ilişkili olarak, U-Net, Mask R-CNN-R101-K ve iMask R-CNN-R101-K modellerinin otomatik lezyon tespiti örneklerinde daha geniş alanların tespit edilemediği, iMask R-CNN-R101-D ve iMask R-CNN-RX101-K modellerinden alınan örneklerde hata oranının nispeten daha düşük olduğu görülmektedir.




**Grafik 6.1.** MSAkdeniz Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması



**Şekil 6.1.** MSAkdeniz Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntüler

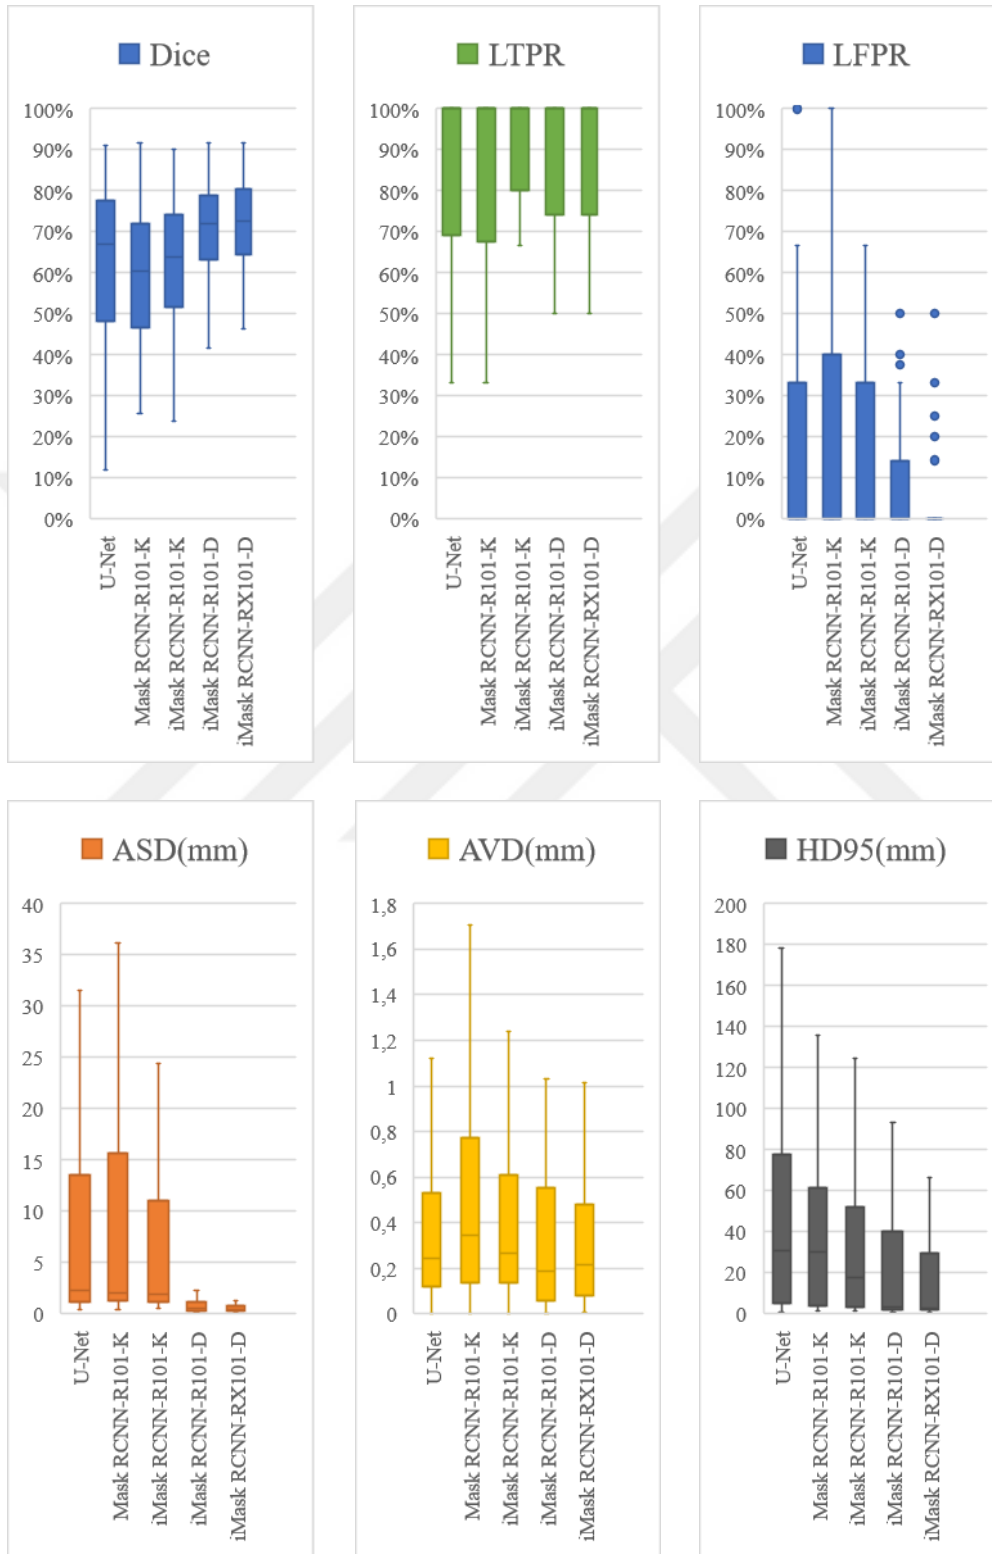
Açık veriseti olan eHealth T2w sekansında alınan görüntülerden oluşmaktadır. Bu nedenle MS lezyonları konusunda zorlu bir veriseti olduğu görülmüştür. MR görüntülerinde lezyonlar ile benzer şekilde beyin duvarlarının renkleri öne çıkmaktadır. Bu durumun da görüntü işleme teknikleri için bir zorluk oluşturduğu gözlenmiştir. Şekil 6.2’de eHealth verisetinde örnek bir MR kesiti görülmektedir. Şekilde de açıkça görüldüğü gibi T2w sekansında olan MR görüntülerinde MS lezyonlarının beyin duvarları ile benzerliği açıkça görülmektedir.



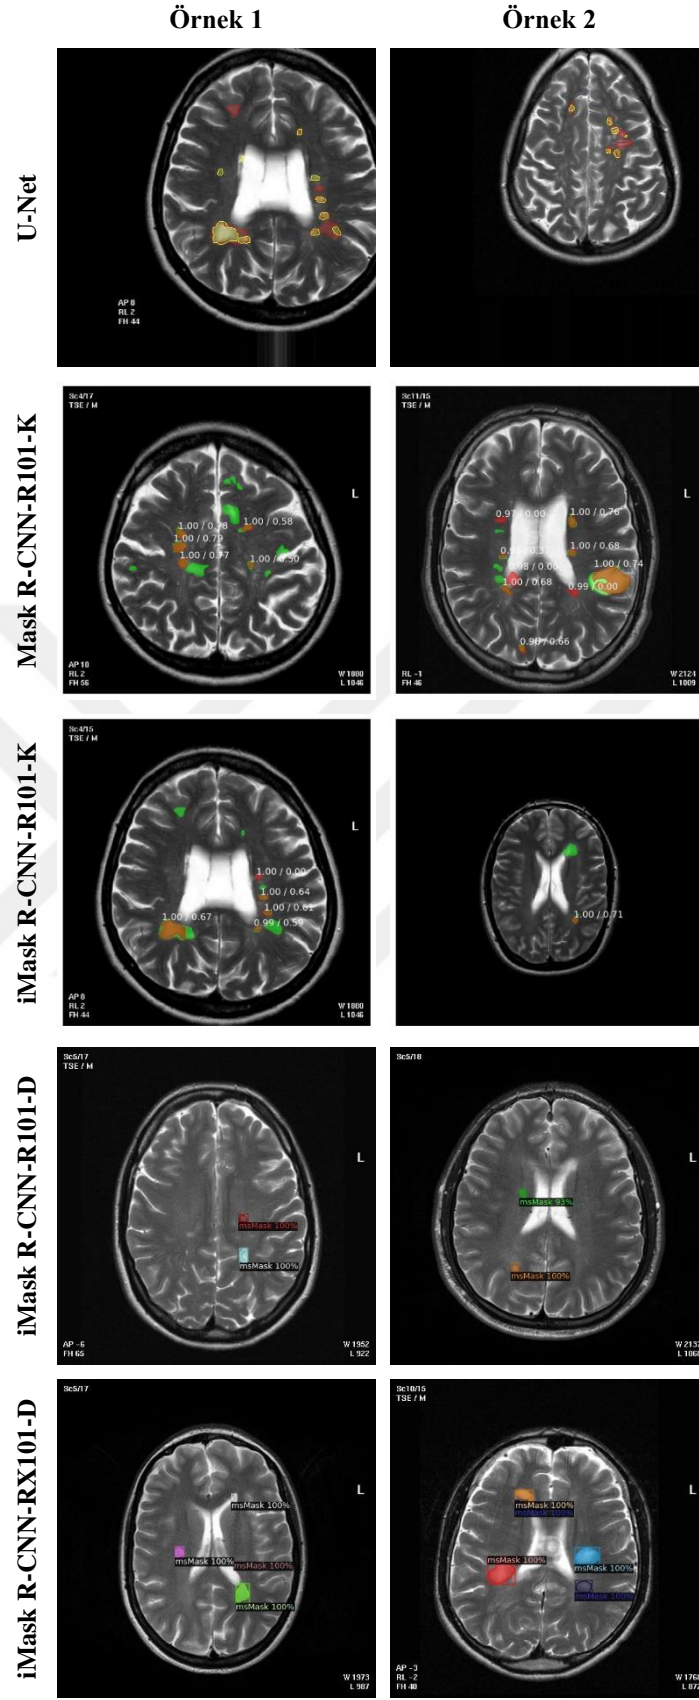
**Şekil 6.2.** eHealth Verisetinden Bir Örnek MR Kesiti ve MS Lezyonları

eHealth veriseti üzerinde derin öğrenme modelleri ile yapılan eğitim ve test süreçlerinin karşılaştırması Grafik 6.2’de görülmektedir. Grafik incelendiğinde yapılan testlerde başarımların gelişimi birçok açıdan görülmektedir. DSC’nin modeller arasında git gide üst sınırdaki kutu oluşturması daha benzer şekilde lezyon sınırlarının belirlendiği anlaşılmaktadır. iMask R-CNN-RX101-D modelinde DSC %89.00 gibi yüksek bir değere ulaşmıştır. HD95 metriğine göre modeller arasında yapılan incelemede lezyon alanlarının iMask R-CNN-RX101-D modelinde 24.3147mm sapma ile en doğru yerde belirlendiğini görülmektedir. iMask R-CNN-R101-D modelinin LFPR metriğinde aykırı değerler görmezden gelindiğinde sıfıra yakın olması, başarısının önemli bir kanıtıdır. eHealth verisetinde iMask R-CNN-RX101-D modeli en başarılı derin öğrenme modeli olarak gözlenmiştir. Deneysel çalışmalar sonucunda MS lezyonları başarıyla tespit edilememiş MR Görüntülerine örnekler Şekil 6.3’te görülmektedir. Şekil incelendiğinde; T2w sekanslı MR kesitlerini içeren verisetinin önerilen modeller ile otomatik lezyon tespiti sürecinde bazı zorluklar olduğu görülmüştür. Deneysel çalışmalarda modellerin otomatik lezyon tespiti sırasında bazı alanları yanlış tespit ettiği veya tespit edilemediği anlaşılmıştır. iMask R-CNN-R101-D ve iMask R-CNN-RX101-D modellerinden alınan

örneklerde hata oranının U-Net ve Mask R-CNN-R101-K ve iMask R-CNN-R101-K'e göre nispeten daha düşük olduğu görülmektedir.



**Grafik 6.2.** eHealth Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması



Şekil 6.3. eHealth Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntüler

eHealth verisetinde literatürde yapılmış önceki çalışmalar incelendiğinde; MS lezyonlarının tespiti için derin öğrenme yöntemlerinde farklı teknikler kullanıldığı görülmüştür. Verisetinin sunulduğu çalışmada histogram normalizasyon yöntemi ile lezyon alanlarının öne çıkarıldığı ön işlem çalışması görülmektedir (Loizou vd., 2009: 1). Başka bir çalışmada Zhang vd. (2018)'de bir derin öğrenme modeli ile lezyon tespiti önermiş (Zhang vd., 2018: 8) ancak test sonuçlarının yerine eğitim başarımını ölçmüştür. Bu veriseti üzerinde önceden yapılan çalışmalar sonucunda elde edilen sonuçlar ve tez kapsamındaki çalışmaların incelenmesi ile elde edilen sonuçların karşılaştırması Tablo 6.1'de görülmektedir.

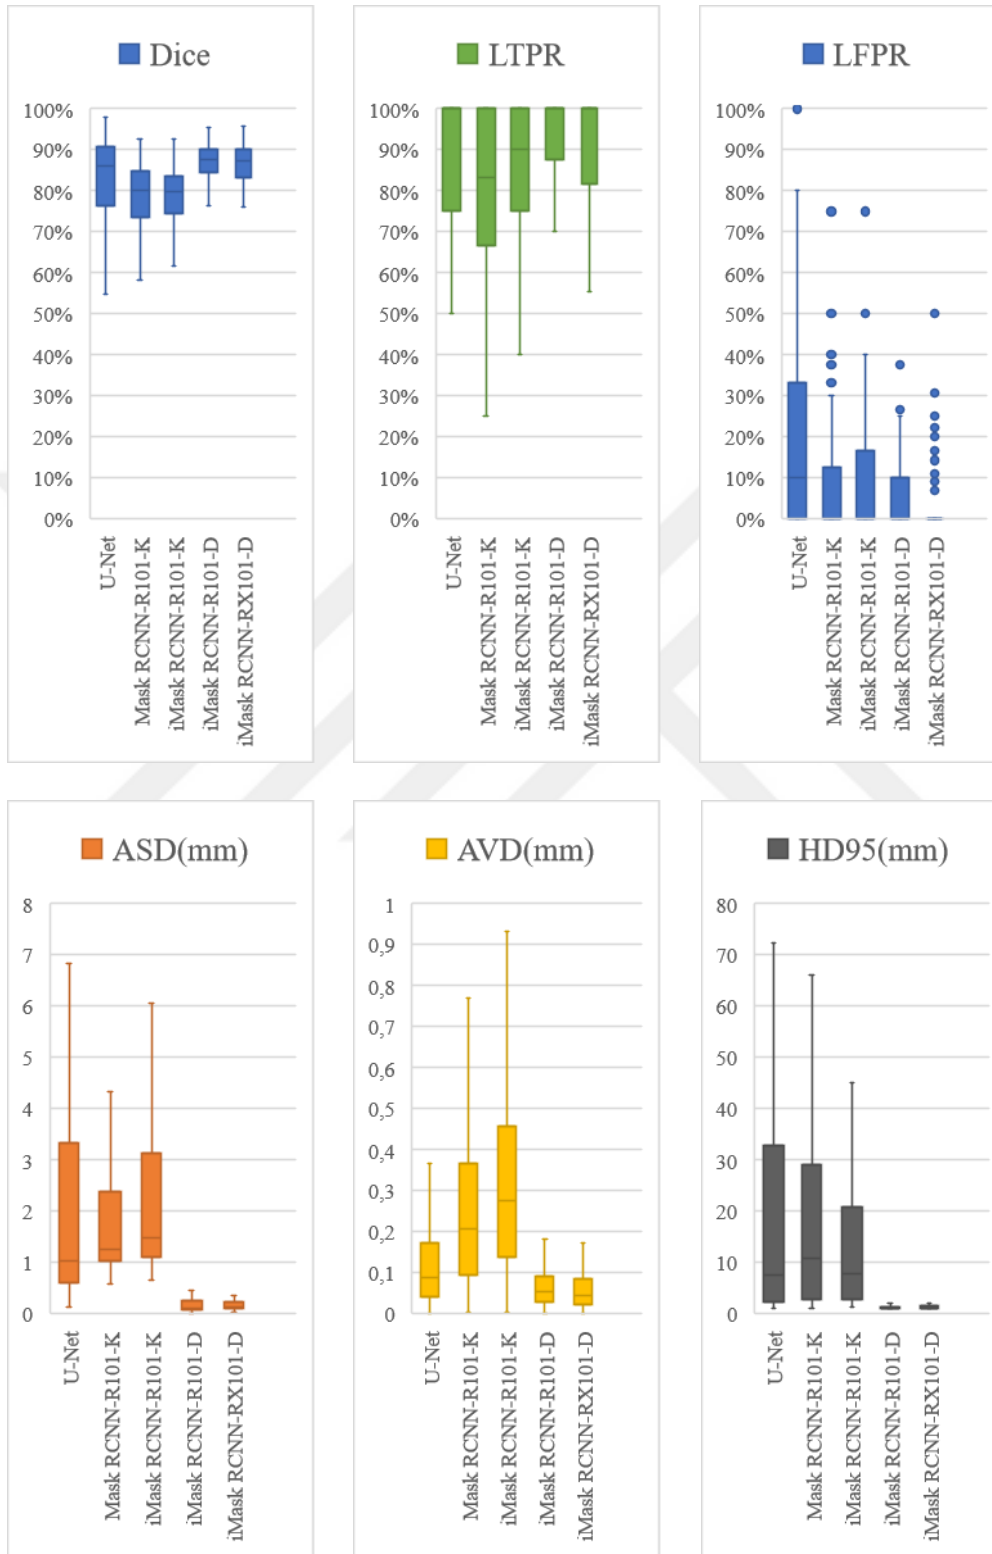
**Tablo 6.1.** eHealth Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması

Çalışma	Metot	DSC (%)	LTPR(%)
(Yıldırım & Dandil, 2020: 14)	iMask R-CNN	84.90	73.75
Tez Çalışması	iMask R-CNN-R101-K	84.59	90.80
Tez Çalışması	iMask R-CNN-R101-D	86.47	86.87
Tez Çalışması	iMask R-CNN-RX101-D	89.00	86.86

Ljubljana Üniversitesi tarafından akademik çalışmalar için sunulan UMCL veriseti MS çalışmalarında kullanılan tüm sekansları içeren bir verisetidir. Çalışma kapsamında verisetinin FLAIR sekanstaki görüntüleri kullanılmıştır. Verisetinin en yüksek çözünürlükteki görüntüleri koronal açıdan alınan kesitlerde olduğu görülmüştür. UMCL'nin karakteristik özelliği olarak MS lezyon alanlarının diğer verisetlerine göre daha büyük alanlara ulaştığı görülmüştür. Bu durum önerilen iMask R-CNN modeli için diğer verisetlerinden farklı bir zorluk oluşturmuştur. Ancak iMask R-CNN-R101-D modeli ile yapılan testlerde %92.24 DSC başarımı ile MS lezyonlarının tespiti konusunda önemli başarımlar elde edilmiştir.

UMCL veriseti üzerinde derin öğrenme modelleri ile gerçekleştirilen eğitim süreçleri sonucunda yapılan test süreçlerinin karşılaştırmalı kutu grafiği Grafik 6.3'te görülmektedir. Kutu grafikleri incelendiğinde; tez kapsamında kullanılan derin öğrenme modellerinden iMask R-CNN-R101-D'nin metriklerin büyük çoğunluğunda öne çıktığı görülmüştür. DSC benzerlik oranında %92.24 ve LTPR oranında %92.45 gibi yüksek değerlere ulaşılması MR görüntüleri üzerinde bulunan lezyonların büyük oranda tespit edildiği ve bunlarında doğru çerçevede tespit edildiğini göstermektedir. iMask R-CNN-RX101-D modelinin ise AVD ve LFPR oranlarında

öne çıkması bu modelin mesafe hatasının ve hatalı lezyon alanı belirleme oranının düşük olduğunu göstermektedir.



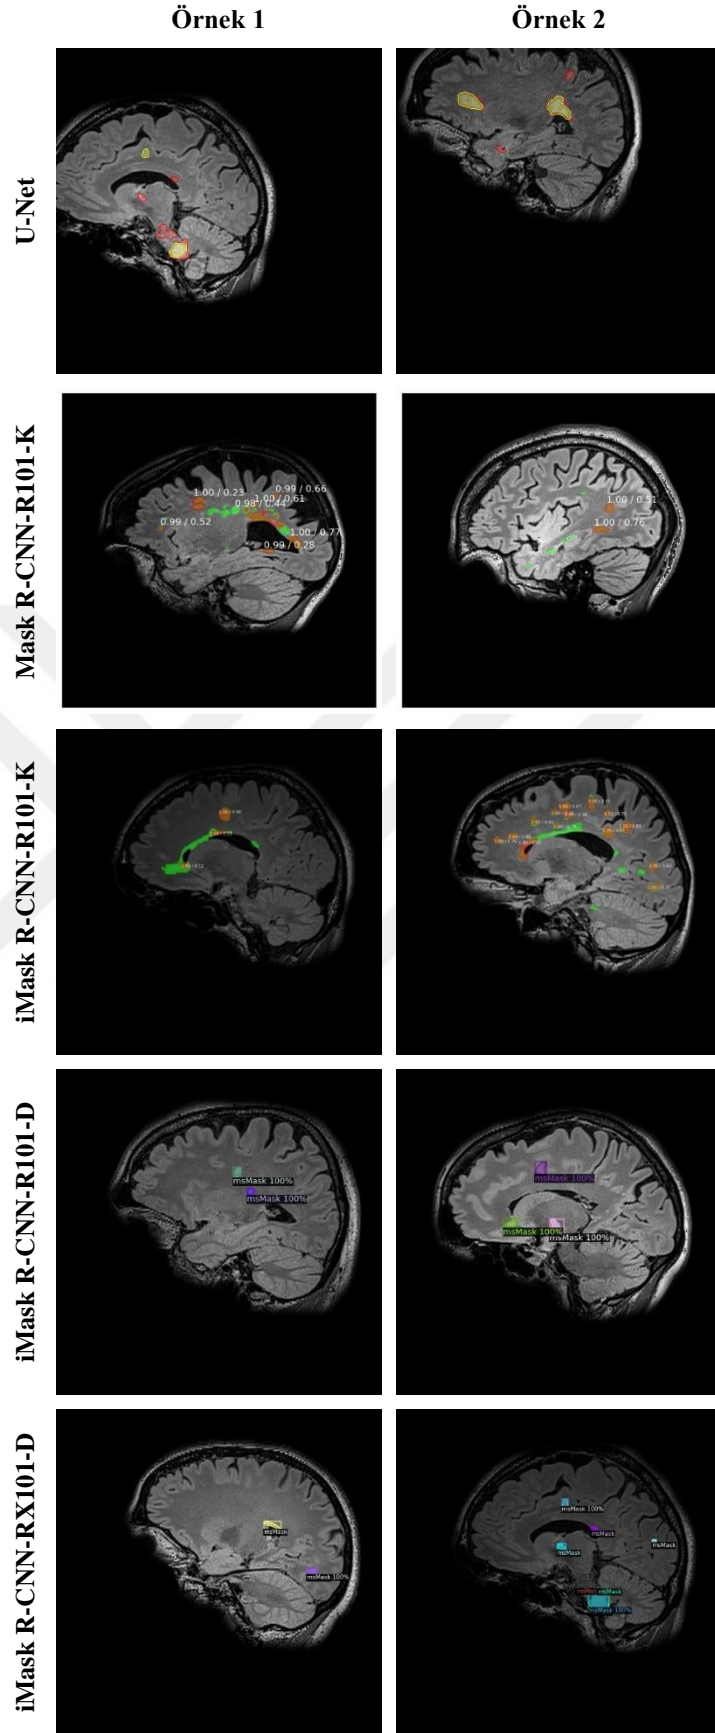
**Grafik 6.3.** UMCL Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması

UMCL verisetinde deneysel çalışmalar sonucunda MS lezyonları başarıyla tespit edilememiş MR görüntülerine örnekler Şekil 6.4'te görülmektedir. Deneysel çalışmalarda modellerin otomatik lezyon tespiti sırasında bazı alanları yanlış tespit ettiği veya tespit edilemediği anlaşılmıştır. Şekilde her model için 2 örnek sunulmuştur. Örneklerde uzman hekimlerin belirlediği lezyon alanları ile sistemin otomatik belirlediği lezyon alanları farklı renklerle öne çıkarılmıştır. Ayrıca sistem tarafından belirlenen lezyon alanlarında otomatik lezyon tespit başarımı da gösterilmiştir. Deneysel çalışmalarda en başarılı model olan iMask R-CNN-R101-D ile hatalı MR görüntüsü oranının ve MRG başına tespit edilemeyen lezyon adedinin azlığı açıkça görülmektedir.

Tablo 6.2'de literatür UMCL verisetini kullanarak yapılan çalışmalar ile tez kapsamında yapılan çalışmaların karşılaştırmalı sonuçları görülmektedir. Önerilen model ile daha önceki çalışmada (Yıldırım & Dandıl, 2020: 14) ki başarıma göre artış sağlandığı görülmektedir. Yapılan yayında MR kesitleri aksiyel açıdan kullanılmıştır. Tez kapsamında yapılan çalışmalarda çözünürlük daha yüksek olduğu ve çekimler koronal açıdan gerçekleştirildiği, eğitim ve test kümesindeki görüntü sayısı artırıldığı için modelin başarımının arttığı görülmektedir. UMCL verisetini kullanarak yapılan önceki akademik çalışmalara göre tez çalışması kapsamındaki modellerin başarımı tabloda açıkça görülmektedir.

**Tablo 6.2.** UMCL Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması

Çalışma	Metot	DSC (%)	LTPR(%)	PPV(%)
(Meissen vd., 2021: 7)	Üretken Düşman Ağ Temelli Yarı Otomatik Çözücü	61.30		
(de Sousa vd., 2021: 1788)	Hafifletilmiş U-Net	68.70		80.30
(de Sousa vd., 2021: 1788)	İki Girişli (T1w ve FLAIR) CNN	73.30		81.60
(Joshi & Sharma, 2021: 1533)	Grafik CNN	76.90		87.50
(Yıldırım & Dandıl, 2020: 14)	Gelişmiş Mask R-CNN	81.86	70.88	
Tez Çalışması	iMask R-CNN-R101-K	84.84	86.14	89.43
Tez Çalışması	iMask R-CNN-R101-D	92.24	92.45	94.19
Tez Çalışması	iMask R-CNN-RX101-D	91.70	91.08	94.77




**Şekil 6.4.** UMCL Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntü Örnekleri

12. Uluslararası Biyomedikal Görüntüleme Sempozyumunda MS lezyonlarının tespiti için düzenlenen yarışma için sunulan ISBI2015 veriseti tez çalışmaları kapsamında kullanılmıştır. Verisetinin diğer verisetlerine göre öne çıkan özelliği ön-işlemden geçmiş olmasıdır. ISBI2015 üzerinde yapılan ön işlem ile MR görüntüsündeki beyin bölgesi dışında kalan alanlar kaldırılmıştır ve kalan alanların renk dağılımı daraltılarak lezyon alanları ve beyin bölgesi öne çıkarılmıştır. (Carass vd., 2017: 77). Şekil 6.5'te verisetinde yapılan ön işleme örnek bir MR kesiti görülmektedir. Verisetinin uzman görüşü işaretlemeleri ön işlemden geçmiş MR görüntüleri üzerinden yapılmıştır.

Tez çalışmaları kapsamında derin öğrenme modelleri üzerinde ISBI2015 veriseti ile eğitim ve test işlemleri gerçekleştirilmiştir. Çalışmalarda ön işlemden geçirilmiş FLAIR sekanstaki aksiyel MR kesitleri kullanılmıştır. Grafik 6.4'de görülen kutu grafikleri ile çalışma yapılan derin öğrenme modellerinin karşılaştırılması mümkündür. Veriseti üzerinde bütün derin öğrenme modelleri etkili bir başarımla sergilemiştir. Grafik 6.4 incelendiğinde iMask R-CNN-RX101-D derin öğrenme modelinin başarımları açıkça görülmektedir. Ancak U-Net modeli LTPR metriği açısından %93.34 ile en iyi sonucu almış ve diğer metriklerde de etkili sonuçlara ulaşmıştır. iMask R-CNN-RX101-D ile DSC benzerlik oranı açısından %90.90 gibi çok yüksek bir seviyeye ulaşılmıştır.

Beyin bölgesinin öne çıkarılması ön işleminin derin öğrenme modelleri ile lezyon tespitinde başarımları arttırıldığı görülmüştür. Model başarımlarındaki farklılıkların hatalı lezyon tespitinde, lezyonların konumlarının tespitinde olduğu görülmüştür.



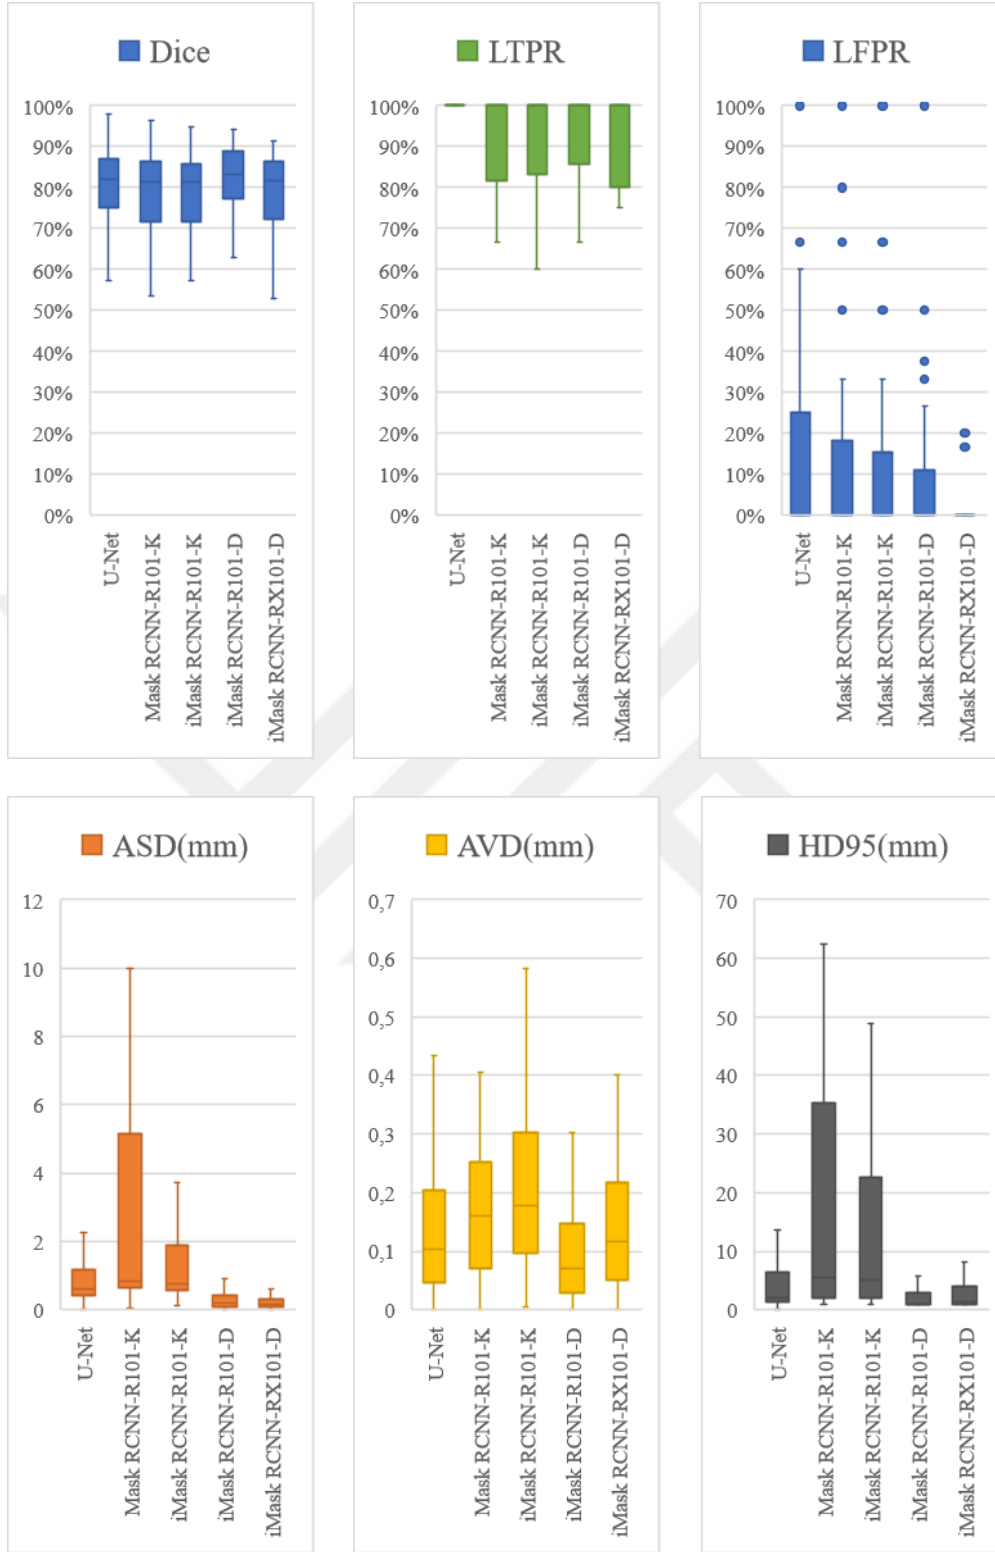
**Şekil 6.5.** ISBI2015 Verisetinin Ön İşlem Yapılmış MR Kesiti Örneği (a) Ön İşlem Yapılmamış MR Kesiti, (b) Ön İşlem Yapılmış MR Kesiti

ISBI2015 veriseti ile farklı derin modelleri ile yapılan deneysel çalışmalar sonucunda otomatik lezyon tespit işlemi yeterli başarıyı görülemediği bazı MR Görüntülerine Şekil 6.6’da görülmektedir. Şekil incelendiğinde, Keras platformunu kullanan modellerde daha büyük hatalı veya eksik lezyon tespiti olduğu görülmüştür.

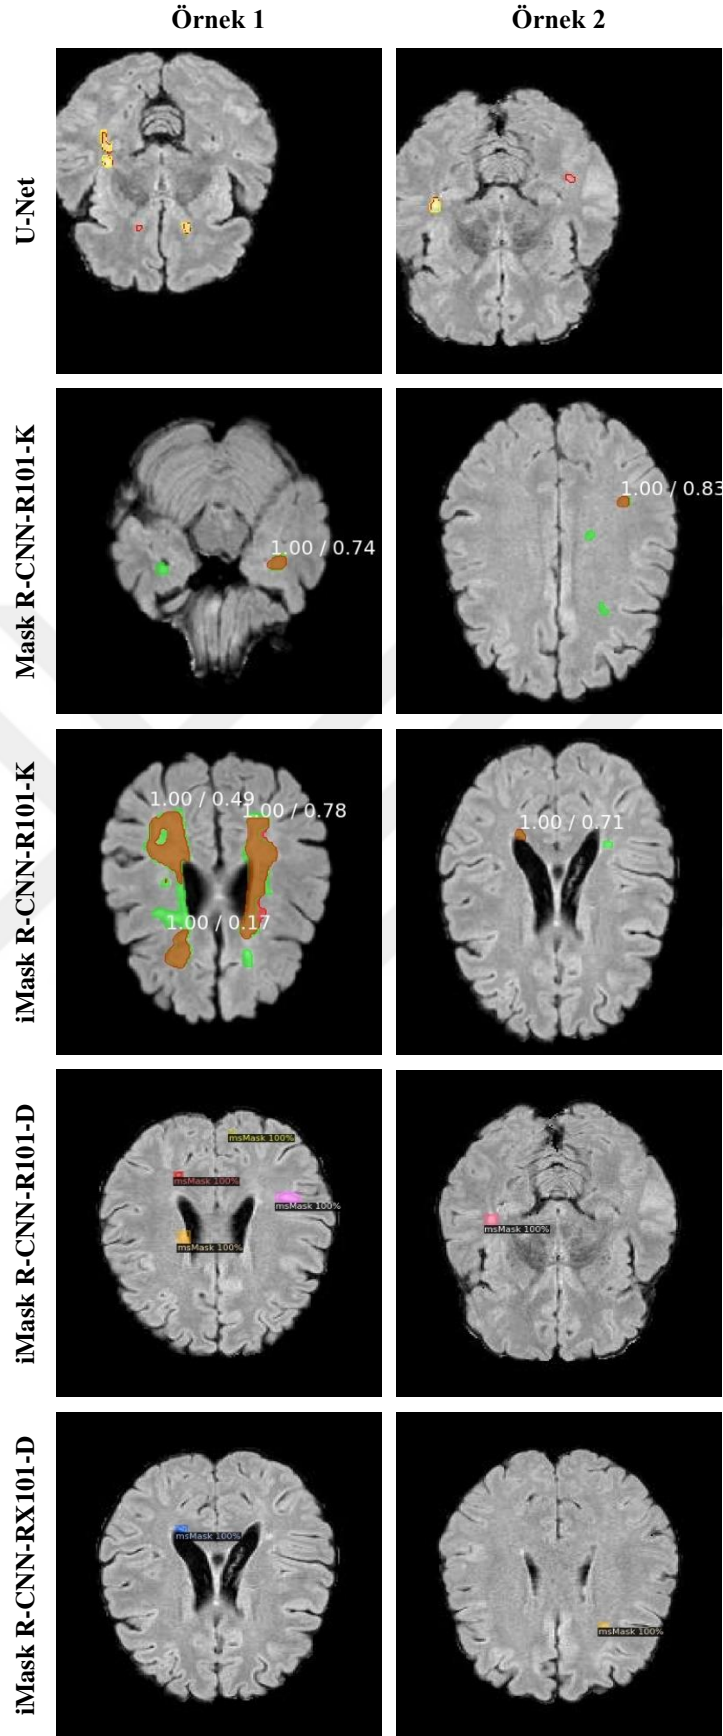
ISBI2015 veriseti ile tez kapsamında gerçekleştirilen çalışmalar ve literatürde daha önce gerçekleştirilen çalışmaların karşılaştırmaları Tablo 6.3’de sunulmuştur. Literatürde sonuçları sunulan çalışmalara göre tez çalışmalarının büyük başarı sağladığı görülmektedir. Bu başarıda modelin katkısı MR kesitleri incelendiğinde açıkça görülmektedir. Ayrıca sunulan çalışmalarda verisetinin içindeki test kümesi üzerinden alınan başarımları olduğu dikkate alınmalıdır. Çalışma kapsamında test verilerinin maskelerine ulaşılmadığı için testler eğitim seti sunulan veriler arasından rastgele seçilerek yapılmıştır. Bu durumda başarıma katkısı olduğu düşünülmektedir.

**Tablo 6.3.** ISBI2015 Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması

Çalışma	Metot	DSC (%)	LTPR(%)	PPV(%)
(Brosch vd., 2016: 1235)	Derin 3B Çözücülü ESA	68.40	78.30	
(Birenbaum & Greenspan, 2017: 117)	Çok Pencereli ESA	62.70		
(de Sousa vd., 2021: 1788)	Hafifletilmiş U-Net	68.70		80.30
(de Sousa vd., 2021: 1788)	İki Girişli (T1w ve FLAIR) ESA	73.30		81.60
(Jacob vd., 2021: 7)	Yarı Otomatik Etiket Eşlemeli ESA	67.55		
(Yıldırım & Dandil, 2021: 575)	Gelişmiş Mask R-CNN	86.30	76.45	
Tez Çalışması	iMask R-CNN-R101-K	86.61	89.43	87.98
Tez Çalışması	iMask R-CNN-R101-D	89.44	89.67	94.52
Tez Çalışması	iMask R-CNN-RX101-D	90.90	91.18	95.11



**Grafik 6.4.** ISBI2015 Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması

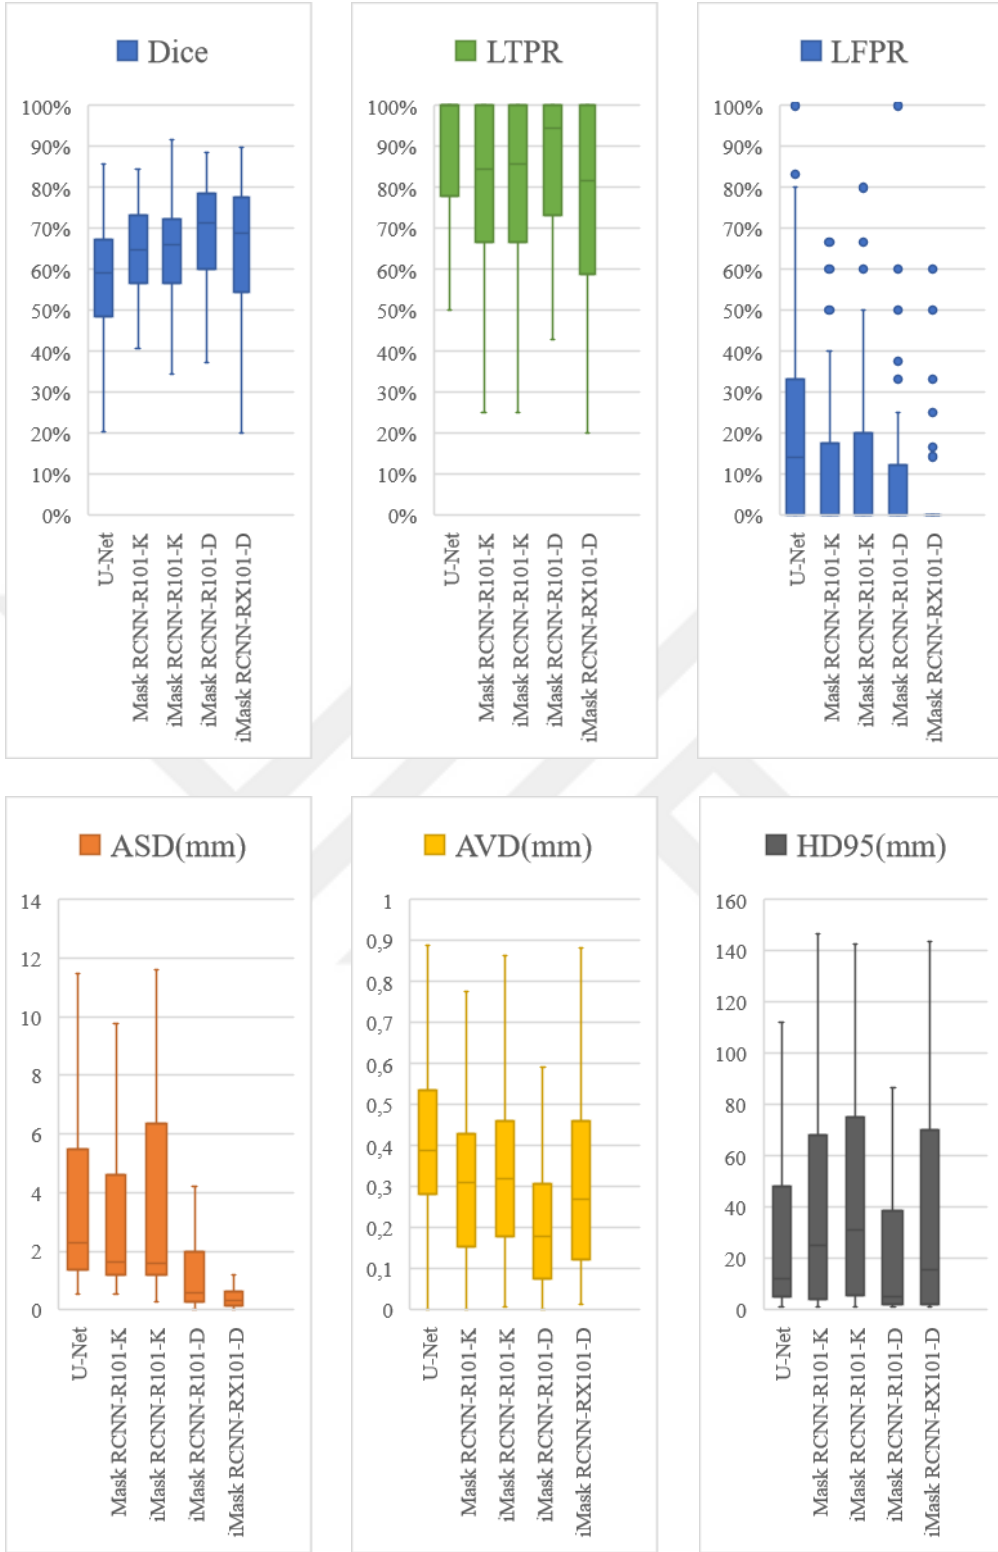


**Şekil 6.6.** ISBI2015 Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntü Örnekleri

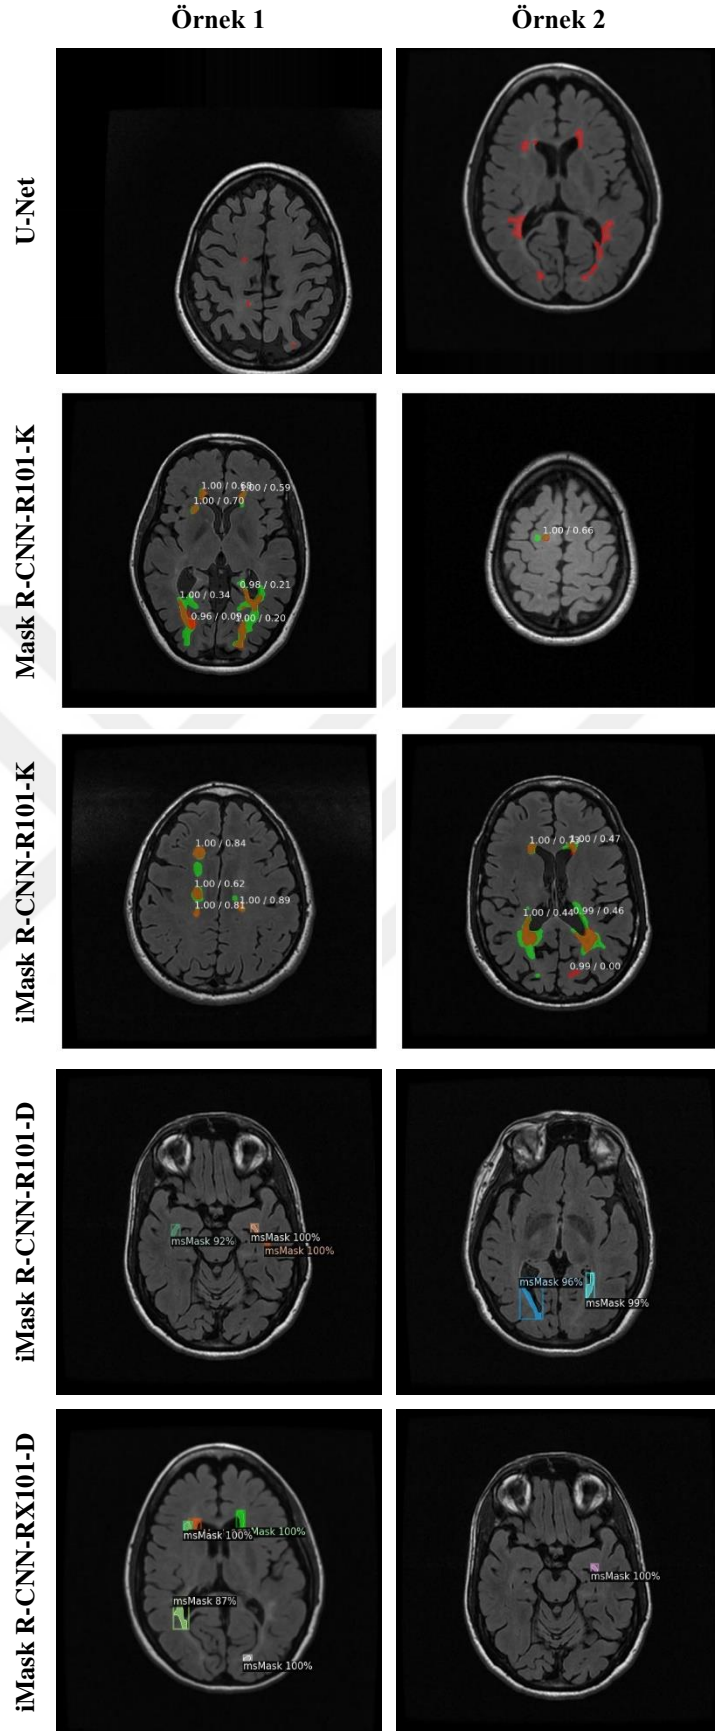
MICCAI2008 11. Uluslararası Tıbbi Görüntü Hesaplama ve Bilgisayar Destekli Müdahale Konferansı kapsamında sunulmuş bir yarışma verisetidir. Tez kapsamında kullanılan verisetlerine göre daha küçük çözünürlüğe sahiptir. Günümüz MR cihazlarından alınan görüntü kalitesi genel olarak bu verisetinin üstündedir. MICCAI2008'in bir diğer zorluğu da iki farklı kaynaktan toplanmış olmasıdır. Farklı cihazlar ile çekilen MR işlemlerinde cihazların çekim parametreleri çekim kalitesinde bazı zorluklar oluşturmaktadır. Veriseti tez kapsamında önerilen modellerin düşük çözünürlüklü ve farklı kaynaklardan alınan MR görüntüleri üzerinde MS lezyonlarının tespiti konusunda test edilmesinde katkı sağlamıştır. Tez çalışması kapsamında önerilen modeller ile veriseti üzerinde eğitim ve testler gerçekleştirilmiştir.

MICCAI2008 veriseti üzerinde önerilen derin öğrenme modelleri ile yapılan testler kutu grafiği şeklinde Grafik 6.5'te sunulmuştur. Grafik incelendiğinde iMask R-CNN-R101-D modelinin başarımının metriklerin çoğunda baskın olduğu görülmektedir. Veriseti bu modelde %83.88 DSC benzerlik oranı ile uzman seçimlerine en yakın lezyon alan benzerliği elde ettiği, %84.37 LTPR ile MR kesitleri üzerindeki lezyon alanlarının en başarılı şekilde tespit ettiği görülmüştür. iMask R-CNN-RX101-D modelinin %4.58 LFPR oranıyla en düşük hatalı lezyon alanı belirleyen model olduğu anlaşılmaktadır. Yapılan deneysel çalışmalar sonucunda MS lezyonları bazı MR kesitlerinde başarıyla tespit edilememiştir. Başarısız tespit sonuçlarına örnek MR görüntüleri her veriseti için iki adet olmak üzere Şekil 6.7'de görülmektedir. Verisetinin çekim kalitesi ve karmaşıklığından kaynaklı olarak bazı MR kesitlerinde doğru tespit edilen lezyon alanı hiç bulunmamaktadır. Deneysel çalışmalarda en başarılı modeller olan iMask R-CNN-R101-D ve iMask R-CNN-RX101-D ile alınan hatalı MR görüntüsü oranının ve MRG başına tespit edilemeyen lezyon adedinin azlığı açıkça görülmektedir.

Tez kapsamında yapılan çalışmalar ile literatürde daha önce gerçekleştirilen çalışmalar içinde MICCAI2008 verisetini kullanan çalışmaların karşılaştırmaları Tablo 6.4'te sunulmuştur. Literatürde sonuçları sunulan çalışmalara göre tez çalışmalarının büyük başarı sağladığı görülmektedir. Bu başarımda modelin katkısı MR kesitleri incelendiğinde açıkça görülmektedir. Ayrıca sunulan çalışmalarda verisetinin içindeki test kümesi üzerinden alınan başarımları olduğu dikkate alınmalıdır. Çalışma kapsamında test verilerinin maskelerine ulaşılmadığı için testler eğitim seti sunulan veriler arasından rastgele seçilerek yapılmıştır. Bu durumda başarıma katkısı olduğu düşünülmektedir.



**Grafik 6.5.** MICCAI2008 Verisetinde Yapılan Testlerin Sonuçlarının Karşılaştırılması



Şekil 6.7. MICCAI2008 Veriseti Üzerinde Yapılan Testlerde MS Lezyonları Tamamen Tespit Edilememiş Bazı Görüntüler

**Tablo 6.4.** MICCAI2008 Veriseti ile Yapılan Önceki Çalışmaların ve Tez Sonuçlarının Karşılaştırması

Çalışma	Metot	DSC (%)	LTPR(%)	PRE(%)
(Geremia vd., 2010: 117)	Uzamsal Rastgele Karar Ağacı			40
(Brosch vd., 2016: 1235)	Derin 3B Çözücülü ESA		51.60	
(Valverde vd., 2017: 165)	Kademeli 3B ESA	56.00		
(Zhao vd., 2018: 98)	Seviye Seti Ayarlamalı Bölütleme	55.00		
(Yıldırım & Dandıl, 2021: 575)	Gelişmiş Mask R-CNN	81.32	68.82	
Tez Çalışması	U-Net	66.21	75.78	71.50
Tez Çalışması	iMask R-CNN-R101-K	80.73	81.43	87.06
Tez Çalışması	iMask R-CNN-R101-D	83.88	84.37	88.89
Tez Çalışması	iMask R-CNN-RX101-D	83.48	80.38	93.91

Tez kapsamındaki deneysel çalışmalarda test edilen derin öğrenme modelleri iki farklı ortamda test edilmiştir. Bu ortamlar Keras ve Detectron2'dir. Keras ortamında matterport-maskrcnn (Abdulla, 2018) kütüphanesinde geliştirme yapılmıştır. Detectron2 ortamında kendi içinde bulunan mask-rcnn kütüphaneleri üzerinde geliştirme yapılmıştır. Yapılan testlerde %99.98 oranıyla Detectron2 ortamının Keras'a göre daha başarılı olduğu görüşmüştür.

Tez çalışmaları kapsamında önerilen iMask R-CNN-R101-K derin öğrenme modelini kullanarak Flask tabanlı bir KDS geliştirilmiştir. DeepMSWeb isimli KDS ile MS lezyonların tespit ve değişimlerinin takibi için web uygulama ortamı sağlayan bir çatı sistemi sunulmuştur. DeepMSWeb-KDS ile önerilen çatı sisteminde eHealth veriseti üzerinde yapılan eğitim ile alınan en iyi sonuçları içeren ağırlıklar kullanılmıştır. Çatı sisteminin tasarımında farklı ağ yapıları ve farklı sekanslarda verisetlerinin kullanılması mümkündür. DeepMSWeb sistemi üzerine yapılan testlerde MR kesitleri üzerinde %100 LTPR oranı ile lezyon alanlarının tamamı, %81- %92 arasında DSC ile lezyon alanları büyük bir başarıyla otomatik olarak tespit edilmiştir. Ayrıca DeepMSWeb takip sisteminden alınan takip raporları hekimlerin belirlediği lezyon alanlarına göre incelendiğinde önemli bir başarı sağlandığı gözlenmiştir. Sistem otomatik olarak MS lezyonları üzerindeki değişimleri tamamen tespit etmiştir.

DeepMSWeb KDS uygulaması geliştirilerek hekimlerin MS lezyonların değişimi takibi için bir çatı sunulmuştur. Geliştirilen çatı uygulama tek veriseti ve tek derin öğrenme modeli ile planlanmıştır. Flask tabanlı sistem içerisine Detectron2 platformunun bağlanması

yapılmadığı için iMask R-CNN modeli sadece Keras ortamındaki versiyonu ile uygulamaya entegre edilmiştir. Gelecek çalışmalarda başka derin öğrenme modelleri ve verisetleri ile geliştirilmeye devam edilebilecek bir çatı uygulamadır.

Tez çalışmaları kapsamında yapılan çalışmalarda MS lezyonlarının tespiti farklı verisetlerinde başarıyla sağlanmıştır. Bunun yanında değişimin takibi için bir uygulama önerisi sunulmuştur. Ancak çalışmalar sırasında donanımsal imkanlar, kullanılan kaynakların içerikleri, yazılım sınırlılıkları nedeniyle bazı kısıtlamalar belirlenmiştir.

Derin öğrenme modellerin eğitim ve test süreçlerinin uygulanması için açık verisetlerinden de faydalanılmıştır. Kullanılan verisetleri akademik çalışmalarda öne çıkan ve dünya genelinde düzenlenen yarışma verisetleri arasından seçilmiştir. Açık verisetlerinden yarışma setlerinin eğitim kümelerinin uzman görüşleri beraberinde sunulurken test setlerinin uzman görüşleri sunulmamaktadır. Bunun nedeni yarışma sırasında elde edilen sonuçların otoriteler tarafından ölçülmesidir. Ancak yarışmalar tamamlandığı için sonuçların sistem tarafından sunulması sonlandırılmıştır. Derin öğrenme modellerinin eğitimi ve testi için kullanılan bilgisayar ortamındaki GPU 11GB hafıza kapasitesine sahiptir. Bu nedenle verisetlerinde sunulan tüm görüntülerin kullanımı mümkün olmamıştır. GPU kapasitesi ve test verisetlerinin uzman görüşlerinin eksikliğine çözüm olması için sunulan eğitim kümeleri içerisinden rastgele seçimler ile eğitim ve test verisetleri ayrılarak eğitimler ve testler gerçekleştirilmiştir. Bu yöntem ile bütün setler üzerinde bir örneklem gerçekleştirilmiştir.

## 7. SONUÇ

MS hastalığı MSS'nin yapısını bozan, çoğunlukla genç ve orta yaşlı insanları etkileyen bir nörolojik hastalıktır. MS hastalığında MSS içindeki sinir liflerini çevreleyen miyelin isimli yağ tabakasının zarar görmesine ve iltihaplanmasına neden olur. MS'in oluşma nedeni kesin olarak bilinmemektedir ancak genetik yatkınlık, bağışıklık sistemindeki anormallikler ve çevresel faktörlerin etkili olduğunu gösteren çalışmalar bulunmaktadır. Hastalığın kaynağı tam belirlenemese de DSÖ raporları detaylıca incelendiğinde yaşayan her 3000 kişiden birinde MS hastalığı olduğu, her 5 dakikada bir kişiye MS teşhisi konulduğu görülmektedir. Günümüzde, dünya genelinde kayıtlı 2.8 milyon MS hastasının olduğu bilinmektedir. MS nedeniyle hastalarda görme keskinliğinde ve kas gücünde azalma, reflekslerde ve dokunma duyusunda kayıplar, yürüme zorluğu görülebilmektedir. Hastalığın ilerlediği durumlarda beyin kapasitesinde azalma olabilmektedir ve etkileri geri dönülemez şekilde artabilmektedir.

MS'in teşhisinde önemli zorluklar bulunmaktadır ve hastalığın takibi ilerlemenin durdurulması ile tedavi için büyük önem arz etmektedir. Öncelikle MS hastalığı başlangıç seviyesinde iken semptomlar görülebilmesine, tahlil ve tetkiklerde şüphe oluşmasına rağmen MR kesitleri üzerinde lezyonlar beyin bölgesi içinde gözle inceleme için küçük boyutlarda kalabilmektedir. Bunun yanında, ilerleyen safhalarda büyüyen lezyonlar ve etki alanları başka rahatsızlıklara da benzeyebilmektedir.

Bu tez çalışmasına “*MS lezyonlarının tespiti ve değişiminin takibi için güçlü bir derin öğrenme modeli geliştirilebilir mi?*” sorusu ve “*Geliştirilen derin öğrenme modeli ile MS lezyonlarının tespiti ve değişiminin takibinde bilgisayar destekli bir karar destek sistemi önerilmeli*” önermesi ile başlanmıştır. Çalışmalar sonucunda MS lezyonlarının otomatik tespiti için, özellikle küçük lezyonların tespitini kolaylaştıran esnek bölge tahminine dayalı iyileştirilmiş bir derin öğrenme modeli (iMask R-CNN) önerilmiş ve modelin doğruluğu beş farklı veriseti üzerinde değerlendirilmiştir. Tez kapsamında, ayrıca geliştirilen iMask R-CNN modeli kullanılarak otomatik lezyon tespiti ve lezyonlardaki değişimin takibi için bir DeepMSWeb isimli KDS de önerilmiştir. Ek olarak, tezde deneysel çalışmaların başarımını arttırmak ve bu alandaki bilimsel çalışmalara destek sağlayabilmek için MSAkdeniz isimli bir de veriseti hazırlanmıştır.

Tez çalışmasında, Mask R-CNN mimarisinde RoI alanlarının seçimi sırasında lezyon boyutlarına göre detaylı arama ve seçim yapan bir iyileştirme yapılmıştır ve iMask R-CNN adında bir derin öğrenme modeli olarak sunulmuştur. Geliştirilen modelin başarımı, U-Net,

standart Mask R-CNN ile ResNet101 ve ResNeXt101 omurga yapılarının birlikte kullanımı ile farklı yapılarda oluşturularak beş farklı veriseti ile karşılaştırılmıştır. Yapılan karşılaştırmalar sonucunda U-Net, Mask R-CNN-R101-K, iMask R-CNN-R101-K, iMask R-CNN-R101-D ve iMask R-CNN-RX101-D modelleri ile yapılan testlerde DSC oranları açısından sırasıyla MSAkdeniz veriseti ile %82.55, %83.64, %81.97, %83.47 ve %85.59; eHealth veriseti ile %65.29, %79.02, %84.59, %86.47 ve %89.00; UMCL veriseti ile %79.42, %82.35, %84.84, %92.24 ve %91.70; ISBI2015 veriseti ile %78.93, %86.91, %86.61, %89.44 ve %90.90 ve MICCAI2008 veriseti ile %66.21, %82.07, %80.73, %83.88 ve %83.48 skorları başarılmıştır.

Tez çalışmasında, iyileştirilen iMask R-CNN derin öğrenme modeli kullanılarak hekimlerin teşhis ve değişimin takibi için kullanabilecekleri web tabanlı bir KDS olan DeepMSWeb ortamı da sunulmuştur. DeepMSWeb lezyonların otomatik tespitini sağlayan bir sistem ve değişimin takibini içeren bir sistem olmak üzere iki sistemden oluşan bir KDS'dir. Her iki sistemde de MR görüntüleri derin öğrenme modeline gönderilerek lezyonların otomatik tespiti ve varsa lezyonlardaki değişimin takibi de mümkündür. Ayrıca, otomatik tespit edilen lezyonlar ile sisteme yüklenen önceden belirlenmiş MS lezyon alanlarının (maske) karşılaştırılarak sistemin başarımının doğrulanması da gerçekleştirilebilmektedir. DeepMSWeb platformunun geliştirme aşamasında en önemli zorluk farklı iki periyotta aynı hastadan alınan MR kesitlerinin karşılaştırılması olmuştur. Hastaların her MR çekimi sırasında milimetrik olarak çoğunlukla aynı konuma gelmesinin zor olmasından dolayı, kesitlerin örtüşmesini sağlayan yeni bir algoritma olan ÖTA geliştirilmiştir. Bu algoritma sayesinde kesitlerin açısız değişikliklerin etkilerinden kurtulması ve değişim oranının hesaplanması sağlanmıştır. Sistem bu sayede lezyon alanlarındaki değişimleri hacimsel olarak ölçerek yüzdelerle tespit sağlayabilmektedir.

Tez çalışması kapsamında literatüre sağlanan en önemli katkılardan birisi de hazırlanan MSAkdeniz verisetidir. Bu veriseti 52 hastanın periyodik MR çekiminden oluşmaktadır. Uzman hekimler tarafından MS lezyon alanları (maskeler) belirlenmiştir. Veriseti sayesinde MS tespiti konusunda uzun yıllar farklı teknikler ile akademik çalışmalar yapılabileceği değerlendirilmektedir.

Özet olarak, derin öğrenme modellerin kullanılarak MS lezyonlarının tespiti ve lezyonlardaki değişimlerin takibi için önerilen bu tez çalışmasının öne çıkan noktaları ve katkıları aşağıdaki gibi listelenebilir:

- i. Tez çalışmasında, MS lezyonlarının tespiti ve lezyonlardaki değişiminin takibi üzerine kapsamlı bir literatür incelemesi yapılmıştır ve var olan çalışmalar ile tez çalışmasının karşılaştırılması yapılmıştır.
- ii. Tezde MS hastalığının tespiti ve değişimlerin izlenmesi konusunda yapılacak akademik çalışmalara katkı sağlamak için MSAkdeniz adında bir veriseti hazırlanmıştır. Bu veriseti <https://github.com/deepmsweb/MSAkdeniz> hesabından açık olarak paylaşılmıştır.
- iii. MS lezyonlarının tespiti için önerilen yöntemin doğruluğunu göstermek için daha önce literatürde sunulmuş olan eHealth, Ljubljana, ISBI2015 ve MICCAI 2008 açık verisetleri tezdeki deneysel çalışmalarda kullanılmıştır ve sonuçlar kıyaslamalı sunulmuştur.
- iv. Tez çalışmasında, MS lezyonlarının tespiti için özellikle küçük lezyonların belirlenmesini kolaylaştıran esnek bölge tahminine dayalı iyileştirilmiş bir derin öğrenme modeli olan iMask R-CNN sunulmuştur.
- v. İyileştirilen iMask R-CNN mimarisinin farklı platformlar ve omurga yapıları ile kullanılması sağlanarak iMask RCNN-R101-K, iMask RCNN-R101-D, iMask RCNN-RX101-D versiyonları oluşturulmuştur ve elde edilen sonuçlar birbiri ile kıyaslanmıştır.
- vi. Ayrıca tez çalışmasında, U-Net, Mask R-CNN ve iMask R-CNN modelleri de birbiri ile karşılaştırılarak derin öğrenme modellerinin MS lezyonlarının tespitindeki sınırlılıkları incelenmiştir.
- vii. Tezde, iMask R-CNN mimarisinde ResNet ve ResNeXt omurga yapıları kullanılarak MS lezyonlarının tespit edilmesindeki etkileri değerlendirilmiştir.
- viii. Mask R-CNN mimarisi için farklı geliştirme ortamı sunan Detectron2 ve Keras platformlarının karşılaştırmalı incelemesi yapılmıştır.
- ix. Doktora Tezi kapsamında, hekimlerin karar verme aşamasında ikincil bir araç olarak yararlanabilecekleri, MS lezyonlarının teşhisi ve takibinde kullanabilecekleri web tabanlı karar destek sistemi olan DeepMSWeb (<https://github.com/deepmsweb/deepmsweb>) uygulaması geliştirilmiştir ve belirtilen bağlantıda paylaşımına açılmıştır. DeepMSWeb zeki karar destek sistemi olup, yapısında iMask R-CNN kullanan derin öğrenme temelli bir web uygulamasını barındırmaktadır.
- x. Tez çalışmasında, DeepMSWeb KDS'nin yapısında, kesitlerin örtüşmesini sağlayan yeni bir algoritma olan ÖTA önerilmiştir. Bu algoritma sayesinde

kesitlerin açısai deęişikliklerden kurtulması ve deęişim oranının hesaplanması başarılı bir şekilde sağlanmıştır.

- xi. Tez kapsamında, yürütölen deneysel analizler sonucunda MS lezyonlarının tespitinde literatürde daha önce önerilmiş olan çalışmalara göre öne çıkan bir başarıml sağlanmıştır. Geliştirilen RoI-Hizalama ile lezyon alanlarında başarıml sağlayan iMask R-CNN modeli ile bir SCI-E indeksli makale yayını (Yıldırım & Dandıl, 2020: 14), bir uluslararası sempozyumda bildirisi (Yıldırım & Dandıl, 2021: 570) tamamlanmıştır. Ayrıca, DeepMSWeb KDS yapısında bulunan MS lezyonlarının tespiti kısmı ile ilgili bir uluslararası sempozyum bildirisi (Yıldırım & Dandil, 2021: 1) yayınlanmıştır.

Tez çalışması kapsamında derin öğrenme modelleri üzerinde yapılan geliştirmeler ile MS lezyonlarına bir model ortaya konulmuştur. Gelecek çalışmalarda MR kesitleri üzerinde MS lezyonlarında olduđu gibi diđer rahatsızlıklarda da başarıml sağlayacak bir model geliştirilmesi planlanmaktadır. Deneysel çalışmalarda dört farklı eğitim modeli ve iki farklı platform üzerinde çalışmalar gerçekleştirilmiştir. Gelecek çalışmalarda MS lezyonlarının tespiti ve deęişimin takibinde kullanılabilir yeni derin öğrenme modellerinin yapılarının incelenmesi planlanmaktadır.

## KAYNAKLAR

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., & Devin, M.** (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*.
- Abdollahpour, I., Lizarraga, A. A., Nedjat, S., Mansournia, M. A., & Weinstock-Guttman, B.** (2019). Medical history and multiple sclerosis: a population-based incident case-control study. *Neuroepidemiology*, 52(1-2), 55-62.
- Abdulla, W.** (2018). Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow: matterport/Mask\_RCNN: Python, Matterport, Inc. Retrieved from [https://github.com/matterport ...](https://github.com/matterport...).
- Admasu, F., Al-Zubi, S., Toennies, K., Bodammer, N., & Hinrichs, H.** (2003). Segmentation of multiple sclerosis lesions from MR brain images using the principles of fuzzy-connectedness and artificial neuron networks. *Proceedings 2003 International Conference on Image Processing (Cat. No. 03CH37429)*.
- Ahmadi, A., Davoudi, S., & Daliri, M. R.** (2019). Computer Aided Diagnosis System for multiple sclerosis disease based on phase to amplitude coupling in covert visual attention. *Computer methods and programs in biomedicine*, 169, 9-18.
- Ahn, S. H., Yeo, A. U., Kim, K. H., Kim, C., Goh, Y., Cho, S., Lee, S. B., Lim, Y. K., Kim, H., & Shin, D.** (2019). Comparative clinical evaluation of atlas and deep-learning-based auto-segmentation of organ structures in liver cancer. *Radiation Oncology*, 14(1), 1-13.
- Albawi, S., Mohammed, T. A., & Al-Zawi, S.** (2017). Understanding of a convolutional neural network. *2017 international conference on engineering and technology (ICET)*.
- Atienza, R.** (2020). *Advanced Deep Learning with TensorFlow 2 and Keras: Apply DL, GANs, VAEs, deep RL, unsupervised learning, object detection and segmentation, and more*: Packt Publishing Ltd.
- Atlas, M.** (2020). *Atlas of MS, 3rd Edition*. Retrieved from <https://www.atlasofms.org/>
- Atlason, H. E., Love, A., Sigurdsson, S., Gudnason, V., & Ellingsen, L. M.** (2019). SegAE: Unsupervised white matter lesion segmentation from brain MRIs using a CNN autoencoder. *NeuroImage: Clinical*, 24, 102085.
- Bakshi, R.** (2003). Fatigue associated with multiple sclerosis: diagnosis, impact and management. *Multiple Sclerosis Journal*, 9(3), 219-227.
- Barrientos, R. V., Schaerer, C., Torres, M. G., & Marrufo, M. V.** (2018). Diagnosis of multiple sclerosis from EEG signal analysis using Empirical Mode Decomposition and Support

Vector Machine. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, 6(2).

**Bethune, A., Tipu, V., Sled, J., Narayanan, S., Arnold, D., Mabbott, D., Rockel, C., Ghassemi, R., Till, C., & Banwell, B.** (2011). Diffusion tensor imaging and cognitive speed in children with multiple sclerosis. *Journal of the neurological sciences*, 309(1-2), 68-74.

**Birenbaum, A., & Greenspan, H.** (2017). Multi-view longitudinal CNN for multiple sclerosis lesion segmentation. *Engineering Applications of Artificial Intelligence*, 65, 111-118.

**Bosc, M., Heitz, F., Armspach, J.-P., Namer, I., Gounot, D., & Rumbach, L.** (2003). Automatic change detection in multimodal serial MRI: application to multiple sclerosis lesion evolution. *NeuroImage*, 20(2), 643-656.

**Bölük, C., Börü, Ü. T., Taşdemir, M., & Gezer, T.** (2021). Epidemiology of Multiple Sclerosis in Turkey; A Ten-Year Trend in Rural Cities. *Turkish Journal of Neurology/Turk Noroloji Dergisi*, 27(1).

**Brosch, T., Tang, L. Y., Yoo, Y., Li, D. K., Traboulsee, A., & Tam, R.** (2016). Deep 3D convolutional encoder networks with shortcuts for multiscale feature integration applied to multiple sclerosis lesion segmentation. *IEEE transactions on medical imaging*, 35(5), 1229-1239.

**Brosch, T., Yoo, Y., Tang, L. Y., Li, D. K., Traboulsee, A., & Tam, R.** (2015). Deep convolutional encoder networks for multiple sclerosis lesion segmentation. *International Conference on Medical Image Computing and Computer-Assisted Intervention*.

**Browne, P., Chandraratna, D., Angood, C., Tremlett, H., Baker, C., Taylor, B. V., & Thompson, A. J.** (2014). MS 2013: Mapping Multiple Sclerosis around the World. 2 Specifically, the goals were to update the information in the Atlas of MS Web site (www.atlasofms.org) and to map data, resources, and services by compiling and calculating their distribution by country, by the 6 WHO. *Neurology*, 83, 1023.

**Brownlee, W. J., Hardy, T. A., Fazekas, F., & Miller, D. H.** (2017). Diagnosis of multiple sclerosis: progress and challenges. *The Lancet*, 389(10076), 1336-1346.

**Burget, R., Šmirg, O., Keřkovský, M., Smékal, Z., & Šprláková-Puková, A.** (2011). Automatic segmentation of focal lesions in the brain, using artificial intelligence methods.

**Cabezas, M., Oliver, A., Roura, E., Freixenet, J., Vilanova, J. C., Ramió-Torrentà, L., Rovira, À., & Lladó, X.** (2014). Automatic multiple sclerosis lesion detection in brain MRI by FLAIR thresholding. *Computer methods and programs in biomedicine*, 115(3), 147-161.

**Calabresi, P. A.** (2004). Diagnosis and management of multiple sclerosis. *American family physician*, 70(10), 1935-1944.

**Carass, A., Roy, S., Jog, A., Cuzzocreo, J. L., Magrath, E., Gherman, A., Button, J., Nguyen, J., Prados, F., Sudre, C. H., Jorge Cardoso, M., Cawley, N., Ciccarelli, O., Wheeler-Kingshott, C. A. M., Ourselin, S., Catanese, L., Deshpande, H., Maurel, P., Commowick, O., Barillot, C., Tomas-Fernandez, X., Warfield, S. K., Vaidya, S., Chunduru, A., Muthuganapathy, R., Krishnamurthi, G., Jesson, A., Arbel, T., Maier, O., Handels, H., IHEME, L. O., Unay, D., Jain, S., Sima, D. M., Smeets, D., Ghafoorian, M., Platel, B., Birenbaum, A., Greenspan, H., Bazin, P. L., Calabresi, P. A., Crainiceanu, C. M., Ellingsen, L. M., Reich, D. S., Prince, J. L., & Pham, D. L. (2017).** Longitudinal multiple sclerosis lesion segmentation: Resource and challenge. *NeuroImage*, *148*, 77-102. doi:10.1016/j.neuroimage.2016.12.064

**Cavaliere, C., Vilades, E., Alonso-Rodríguez, M., Rodrigo, M. J., Pablo, L. E., Miguel, J. M., López-Guillén, E., Morla, E. M., Boquete, L., & Garcia-Martin, E. (2019).** Computer-aided diagnosis of multiple sclerosis using a support vector machine and optical coherence tomography features. *Sensors*, *19*(23), 5323.

**Cerasa, A., Bilotta, E., Augimeri, A., Cherubini, A., Pantano, P., Zito, G., Lanza, P., Valentino, P., Gioia, M. C., & Quattrone, A. (2012).** A cellular neural network methodology for the automated segmentation of multiple sclerosis lesions. *Journal of neuroscience methods*, *203*(1), 193-199.

**Chawla, S., Kister, I., Sinnecker, T., Wuerfel, J., Brisset, J.-C., Paul, F., & Ge, Y. (2018).** Longitudinal study of multiple sclerosis lesions using ultra-high field (7T) multiparametric MR imaging. *PloS one*, *13*(9), e0202918.

**Chollet F. (2022).** Image preprocessing – Keras documentation. <https://keras.io/api/preprocessing/image/>

**Compston, A., & Coles, A. (2002).** Multiple sclerosis. *Lancet (British edition)*, *359*(9313), 1221-1231.

**Contrò, V., Schiera, G., Macchiarella, A., Alessia, S., Lombardo, G., & Proia, P. (2017).** Multiple sclerosis: Physical activity and well-being.

**Cree, B. A. C., Arnold, D. L., Chataway, J., Chitnis, T., Fox, R. J., Ramajo, A. P., Murphy, N., & Lassmann, H. (2021).** Secondary Progressive Multiple Sclerosis: New Insights. *Neurology*.

**Çelik, Y., Birgili, Ö., Kiyat, A., Güldiken, B., Özkan, H., Yilmaz, H., Sebahattin, S., Kuşçu, D., Süttaş, N., & Ağaoğlu, J. (2011).** Prevalence of multiple sclerosis in the metropolitan area of Edirne city, Turkey. *Balkan Medical Journal*, *2011*(2), 193-196.

- Dachraoui, C., Mouelhi, A., Drissi, C., & Labidi, S.** (2022). Automated Diagnosis of Multiple Sclerosis Lesions in Brain MRI Using 3D-FLAIR Acquisition. *Proceedings of Sixth International Congress on Information and Communication Technology*.
- Danelakis, A., Theoharis, T., & Verganelakis, D. A.** (2018). Survey of automated multiple sclerosis lesion segmentation techniques on magnetic resonance imaging. *Computerized Medical Imaging and Graphics*, 70, 83-100.
- Daumer, M., Neuhaus, A., Lederer, C., Scholz, M., Wolinsky, J. S., & Heiderhoff, M.** (2007). Prognosis of the individual course of disease-steps in developing a decision support tool for Multiple Sclerosis. *BMC medical informatics and decision making*, 7(1), 1-6.
- de Sousa, I. M., De Oliveira, M., Lisboa-Filho, P. N., & Cardoso, J. D. S.** (2021). Evaluation of the impact of domain adaptation on segmentation of Multiple Sclerosis lesions in MRI. *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*.
- Deguchi, I., Tanahashi, N., & Takao, M.** (2018). Clinical Study of Intravenous, low-dose recombinant tissue plasminogen activator for acute cerebral infarction: comparison of treatment within 3 hours versus 3-4.5 hours. *Journal of Stroke and Cerebrovascular Diseases*, 27(4), 1033-1040.
- Desse, N., Sellier, A., Bernard, C., & Dagain, A.** (2018). Fatal acute disseminated encephalomyelitis (ADEM) after third ventricle colloid cyst resection with ultrasonic aspirator during neuroendoscopic procedure. *Acta neurochirurgica*, 160(9), 1789-1792.
- Detectron2.** (2022). Detectron2 is a platform for object detection. <https://github.com/facebookresearch/detectron2>
- Donati, D.** (2020). Viral infections and multiple sclerosis. *Drug Discovery Today: Disease Models*, 32, 27-33.
- Dutta, A., Gupta, A., & Zissermann, A.** (2016). VGG image annotator (VIA). URL: <http://www.robots.ox.ac.uk/vgg/software/via>, 2.
- Engelhard, M. M., Patek, S. D., Sheridan, K., Lach, J. C., & Goldman, M. D.** (2017). Remotely engaged: lessons from remote monitoring in multiple sclerosis. *International journal of medical informatics*, 100, 26-31.
- Esposito, M., & De Pietro, G.** (2011). An ontology-based fuzzy decision support system for multiple sclerosis. *Engineering Applications of Artificial Intelligence*, 24(8), 1340-1354.
- Farges, V., Hannoun, S., Benini, T., Marignier, R., & Cotton, F.** (2021). MRI to detect and localize the area postrema in multiple sclerosis: The role of 3D-DIR and 3D-FLAIR. *Journal of Neuroimaging*, 31(4), 701-705.

**Fernández, O., Fernández, V., Arbizu, T., Izquierdo, G., Bosca, I., Arroyo, R., Merino, J. G., & De Ramón, E.** (2010). Characteristics of multiple sclerosis at onset and delay of diagnosis and treatment in Spain (the Novo Study). *Journal of neurology*, 257(9), 1500-1507.

**Filippi, M., Horsfield, M. A., Rovaris, M., Yousry, T., Rocca, M. A., Baratti, C., Bressi, S., & Comi, G.** (1998). Intraobserver and interobserver variability in schemes for estimating volume of brain lesions on MR images in multiple sclerosis. *American journal of neuroradiology*, 19(2), 239-244.

**Filippi, M., & Rocca, M. A.** (2007). Conventional MRI in multiple sclerosis. *Journal of Neuroimaging*, 17, 3S-9S.

**Frisch, T., Elkjaer, M. L., Reynolds, R., Michel, T. M., Kacprowski, T., Burton, M., Kruse, T. A., Thomassen, M., Baumbach, J., & Illes, Z.** (2020). Multiple sclerosis atlas: A molecular map of brain lesion stages in progressive multiple sclerosis. *Network and systems medicine*, 3(1), 122-129.

**Gabr, R. E., Coronado, I., Robinson, M., Sujit, S. J., Datta, S., Sun, X., Allen, W. J., Lublin, F. D., Wolinsky, J. S., & Narayana, P. A.** (2020). Brain and lesion segmentation in multiple sclerosis using fully convolutional neural networks: a large-scale study. *Multiple Sclerosis Journal*, 26(10), 1217-1226.

**García-Lorenzo, D., Francis, S., Narayanan, S., Arnold, D. L., & Collins, D. L.** (2013). Review of automatic segmentation methods of multiple sclerosis white matter lesions on conventional magnetic resonance imaging. *Medical image analysis*, 17(1), 1-18.

**Ge, Y.** (2006). Multiple sclerosis: the role of MR imaging. *American journal of neuroradiology*, 27(6), 1165-1176.

**Geraldes, R., Ciccarelli, O., Barkhof, F., De Stefano, N., Enzinger, C., Filippi, M., Hofer, M., Paul, F., Preziosa, P., & Rovira, A.** (2018). The current role of MRI in differentiating multiple sclerosis from its imaging mimics. *Nature Reviews Neurology*, 14(4), 199-213.

**Geremia, E., Menze, B. H., Clatz, O., Konukoglu, E., Criminisi, A., & Ayache, N.** (2010). Spatial decision forests for MS lesion segmentation in multi-channel MR images. *International Conference on Medical Image Computing and Computer-Assisted Intervention*.

**Gessert, N., Bengs, M., Krüger, J., Opfer, R., Ostwaldt, A.-C., Manogaran, P., Schippling, S., & Schlaefer, A.** (2020). 4D deep learning for multiple sclerosis lesion activity segmentation. *arXiv preprint arXiv:2004.09216*.

**Gessert, N., Krüger, J., Opfer, R., Ostwaldt, A.-C., Manogaran, P., Kitzler, H. H., Schippling, S., & Schlaefer, A.** (2020). Multiple sclerosis lesion activity segmentation with attention-guided two-path CNNs. *Computerized Medical Imaging and Graphics*, 84, 101772.

- Ghahazi, M. A., Zarandi, M. F., Harirchian, M., & Damirchi-Darasi, S. R.** (2014). Fuzzy rule based expert system for diagnosis of multiple sclerosis. *2014 IEEE Conference on Norbert Wiener in the 21st Century (21CW)*.
- Ghribi, O., Maalej, A., Sellami, L., Slima, M. B., Maalej, M. A., Mahfoudh, K. B., Dammak, M., Mhiri, C., & Hamida, A. B.** (2019). Advanced methodology for multiple sclerosis lesion exploring: Towards a computer aided diagnosis system. *Biomedical Signal Processing and Control*, 49, 274-288.
- Girshick, R.** (2015). Fast r-cnn. *Proceedings of the IEEE international conference on computer vision*.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J.** (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Goldenberg, M. M.** (2012). Multiple sclerosis review. *Pharmacy and Therapeutics*, 37(3), 175.
- Grinberg, M.** (2018). *Flask web development: developing web applications with python*: " O'Reilly Media, Inc."
- Hashemi, S. R., Salehi, S. S. M., Erdogmus, D., Prabhu, S. P., Warfield, S. K., & Gholipour, A.** (2018). Asymmetric loss functions and deep densely-connected networks for highly-imbalanced medical image segmentation: Application to multiple sclerosis lesion detection. *IEEE Access*, 7, 1721-1735.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R.** (2017). Mask r-cnn. *Proceedings of the IEEE international conference on computer vision*.
- Hindsholm, A. M., Cramer, S. P., Simonsen, H. J., Frederiksen, J. L., Andersen, F., Højgaard, L., Ladefoged, C. N., & Lindberg, U.** (2021). Assessment of Artificial Intelligence Automatic Multiple Sclerosis Lesion Delineation Tool for Clinical Use. *Clinical Neuroradiology*, 1-11.
- Hosseini, A., Asadi, F., & Arani, L. A.** (2020). Development of a Knowledge-based Clinical Decision Support System for Multiple Sclerosis Diagnosis. *Journal of Medicine and Life*, 13(4), 612.
- Huang, W. J., Chen, W. W., & Zhang, X.** (2017). Multiple sclerosis: pathology, diagnosis and treatments. *Experimental and therapeutic medicine*, 13(6), 3163-3166.
- Inojosa, H., Proschmann, U., Akgün, K., & Ziemssen, T.** (2021). A focus on secondary progressive multiple sclerosis (SPMS): challenges in diagnosis and definition. *Journal of neurology*, 268(4), 1210-1221.

- Islam, T., Gauderman, W. J., Cozen, W., Hamilton, A. S., Burnett, M. E., & Mack, T. M.** (2006). Differential twin concordance for multiple sclerosis by latitude of birthplace. *Annals of neurology*, 60(1), 56-64.
- Jaccard, P.** (1912). The distribution of the flora in the alpine zone. 1. *New phytologist*, 11(2), 37-50.
- Jacob, J., Ciccarelli, O., Barkhof, F., & Alexander, D. C.** (2021). Disentangling Human Error from the Ground Truth in Segmentation of Medical Images.
- Jain, S., Ribbens, A., Sima, D. M., Cambron, M., De Keyser, J., Wang, C., Barnett, M. H., Van Huffel, S., Maes, F., & Smeets, D.** (2016). Two time point MS lesion segmentation in brain MRI: an expectation-maximization framework. *Frontiers in neuroscience*, 10, 576.
- Jain, S., Sima, D. M., Ribbens, A., Cambron, M., Maertens, A., Van Hecke, W., De Mey, J., Barkhof, F., Steenwijk, M. D., & Daams, M.** (2015). Automatic segmentation and volumetry of multiple sclerosis brain lesions from MR images. *NeuroImage: Clinical*, 8, 367-375.
- Joshi, A., & Sharma, K.** (2021). Hybrid Topology of Graph Convolution and Autoencoder Deep Network For Multiple Sclerosis Lesion Segmentation. *2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS)*.
- Kalchbrenner, N., Grefenstette, E., & Blunsom, P.** (2014). A convolutional neural network for modelling sentences. *arXiv preprint arXiv:1404.2188*.
- Kantarci, O. H., Lebrun, C., Siva, A., Keegan, M. B., Azevedo, C. J., Inglese, M., Tintoré, M., Newton, B. D., Durand-Dubief, F., & Amato, M. P.** (2016). Primary Progressive Multiple Sclerosis Evolving From Radiologically Isolated Syndrome. *Annals of neurology*, 79(2), 288-294.
- Karabudak, R.** (2014). Multipl Skleroz (MS). In T. N. Derneği (Ed.).
- Karaca, B. K., Akşahin, M. F., & Öcal, R.** (2021). Detection of multiple sclerosis from photic stimulation EEG signals. *Biomedical Signal Processing and Control*, 67, 102571.
- Karimi, D., & Salcudean, S. E.** (2019). Reducing the hausdorff distance in medical image segmentation with convolutional neural networks. *IEEE transactions on medical imaging*, 39(2), 499-513.
- Kavur, A. E., Gezer, N. S., Barış, M., Şahin, Y., Özkan, S., Baydar, B., Yüksel, U., Kılıkçier, Ç., Olut, Ş., & Akar, G. B.** (2020). Comparison of semi-automatic and deep learning-based automatic methods for liver segmentation in living liver transplant donors. *Diagnostic and Interventional Radiology*, 26(1), 11.

**Kearney, H., Miller, D. H., & Ciccarelli, O.** (2015). Spinal cord MRI in multiple sclerosis—diagnostic, prognostic and clinical value. *Nature Reviews Neurology*, *11*(6), 327-338.

**Keras.** (2022). Keras: the Python deep learning API. <https://keras.io/>

**Khayati, R., Vafadust, M., Towhidkhah, F., & Nabavi, S. M.** (2008). A novel method for automatic determination of different stages of multiple sclerosis lesions in brain MR FLAIR images. *Computerized Medical Imaging and Graphics*, *32*(2), 124-133.

**Kim, H., Shim, E., Park, J., Kim, Y.-J., Lee, U., & Kim, Y.** (2020). Web-based fully automated cephalometric analysis by deep learning. *Computer methods and programs in biomedicine*, *194*, 105513.

**Kim, Y. J., Ganbold, B., & Kim, K. G.** (2020). Web-based spine segmentation using deep learning in computed tomography images. *Healthcare informatics research*, *26*(1), 61-67.

**Kitajima, M., Hirai, T., Shigematsu, Y., Uetani, H., Iwashita, K., Morita, K., Komi, M., & Yamashita, Y.** (2012). Comparison of 3D FLAIR, 2D FLAIR, and 2D T2-weighted MR imaging of brain stem anatomy. *American journal of neuroradiology*, *33*(5), 922-927.

**Knight, J., & Khademi, A.** (2016). MS lesion segmentation using FLAIR MRI only. *Proceedings of the 1st MICCAI challenge on multiple sclerosis lesions segmentation challenge using a data management and processing infrastructure-MICCAI-MSSEG*, 21-28.

**Kobelt, G., Thompson, A., Berg, J., Gannedahl, M., Eriksson, J., Group, M. S., & Platform, E. M. S.** (2017). New insights into the burden and costs of multiple sclerosis in Europe. *Multiple Sclerosis Journal*, *23*(8), 1123-1136.

**Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*.

**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 and Electronics in Agriculture*, *179*, 105842.

**Lana-Peixoto, M. A., Pedrosa, D., Talim, N., Amaral, J. M., Horta, A., & Kleinpaul, R.** (2018). Neuromyelitis optica spectrum disorder associated with dengue virus infection. *Journal of neuroimmunology*, *318*, 53-55.

**Lassmann, H., Van Horsen, J., & Mahad, D.** (2012). Progressive multiple sclerosis: pathology and pathogenesis. *Nature Reviews Neurology*, *8*(11), 647-656.

**Lesjak, Z., Galimzianova, A., Koren, A., Lukin, M., Pernus, F., Likar, B., & Spiclin, Z.** (2018). A Novel Public MR Image Dataset of Multiple Sclerosis Patients With Lesion Segmentations Based on Multi-rater Consensus. *Neuroinformatics*, *16*(1), 51-63. doi:10.1007/s12021-017-9348-7

- Li, R., Liu, W., Yang, L., Sun, S., Hu, W., Zhang, F., & Li, W.** (2018). DeepUNet: A deep fully convolutional network for pixel-level sea-land segmentation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(11), 3954-3962.
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S.** (2017). Feature pyramid networks for object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Liu, W., Wen, Y., Yu, Z., & Yang, M.** (2016). Large-margin softmax loss for convolutional neural networks. *ICML*.
- Lladó, X., Oliver, A., Cabezas, M., Freixenet, J., Vilanova, J. C., Quiles, A., Valls, L., Ramió-Torrentà, L., & Rovira, À.** (2012). Segmentation of multiple sclerosis lesions in brain MRI: a review of automated approaches. *Information Sciences*, 186(1), 164-185.
- Loizou, C. P.** (2012). *eHealth Lab - MRI Lesion Segmentation in Multiple Sclerosis Database* [MR Image Dataset]. <http://ehealthlab.cs.ucy.ac.cy/old/doc/Publications/Datasets/MRIFreeDataset.zip>. <http://www.medinfo.cs.ucy.ac.cy/>
- Loizou, C. P., Pantziaris, M., Seimenis, I., & Pattichis, C. S.** (2009). Brain MR image normalization in texture analysis of multiple sclerosis. *2009 9th International Conference on Information Technology and Applications in Biomedicine*.
- Long, J., Shelhamer, E., & Darrell, T.** (2015). Fully convolutional networks for semantic segmentation. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Ma, K. C., Fernandez, J. R., Amezcua, L., Lerner, A., Shiroishi, M. S., & Liu, B. J.** (2015). Design and development of an ethnically-diverse imaging informatics-based eFolder system for multiple sclerosis patients. *Computerized Medical Imaging and Graphics*, 46, 257-268.
- Mahmoudi, S. E., Akhondi-Asl, A., Rahmani, R., Faghih-Roohi, S., Taimouri, V., Sabouri, A., & Soltanian-Zadeh, H.** (2010). Web-based interactive 2D/3D medical image processing and visualization software. *Computer methods and programs in biomedicine*, 98(2), 172-182.
- Makhani, N., & Tremlett, H.** (2021). The multiple sclerosis prodrome. *Nature Reviews Neurology*, 1-7.
- Maleki, M., Teshnehlab, M., & Nabavi, M.** (2012). Diagnosis of multiple sclerosis (MS) using convolutional neural network (CNN) from MRIs. *Global Journal of Medicinal Plant Research*, 1(1), 50-54.
- Marrodan, M., Alessandro, L., Farez, M. F., & Correale, J.** (2019). The role of infections in multiple sclerosis. *Multiple Sclerosis Journal*, 25(7), 891-901.

**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 and the Child Neurology Society*, 50(1), 121-127.

**McKinley, R., Wepfer, R., Aschwanden, F., Grunder, L., Muri, R., Rummel, C., Verma, R., Weisstanner, C., Reyes, M., & Salmen, A.** (2021). Simultaneous lesion and brain segmentation in multiple sclerosis using deep neural networks. *Scientific reports*, 11(1), 1-11.

**McKinley, R., Wepfer, R., Grunder, L., Aschwanden, F., Fischer, T., Friedli, C., Muri, R., Rummel, C., Verma, R., & Weisstanner, C.** (2020). Automatic detection of lesion load change in Multiple Sclerosis using convolutional neural networks with segmentation confidence. *NeuroImage: Clinical*, 25, 102104.

**Meissen, F., Kaissis, G., & Rueckert, D.** (2021). Challenging Current Semi-Supervised Anomaly Segmentation Methods for Brain MRI. *arXiv preprint arXiv:2109.06023*.

**MetaAI.** (2022). Facebook AI Research. <https://ai.facebook.com/>

**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), 281-288.

**Miller, D., Weinshenker, B. G., Filippi, M., Banwell, B., Cohen, J., Freedman, M., Galetta, S., Hutchinson, M., Johnson, R., & Kappos, L.** (2008). Differential diagnosis of suspected multiple sclerosis: a consensus approach. *Multiple Sclerosis Journal*, 14(9), 1157-1174.

**Miller, D. M., Moore, S. M., Fox, R. J., Atreja, A., Fu, A. Z., Lee, J.-C., Saupe, W., Stadler, M., Chakraborty, S., & Harris, C.** (2011). Web-based self-management for patients with multiple sclerosis: a practical, randomized trial. *Telemedicine and e-Health*, 17(1), 5-13.

**Montalban, X., Gold, R., Thompson, A. J., Otero-Romero, S., Amato, M. P., Chandraratna, D., Clanet, M., Comi, G., Derfuss, T., & Fazekas, F.** (2018).ECTRIMS/EAN guideline on the pharmacological treatment of people with multiple sclerosis. *Multiple Sclerosis Journal*, 24(2), 96-120.

**Mortazavi, D., Kouzani, A. Z., & Soltanian-Zadeh, H.** (2012). Segmentation of multiple sclerosis lesions in MR images: a review. *Neuroradiology*, 54(4), 299-320.

**Nair, T., Precup, D., Arnold, D. L., & Arbel, T.** (2020). Exploring uncertainty measures in deep networks for multiple sclerosis lesion detection and segmentation. *Medical image analysis*, 59, 101557.

- Navikas, V., & Link, H.** (1996). Cytokines and the pathogenesis of multiple sclerosis. *Journal of neuroscience research*, 45(4), 322-333.
- Nayak, D. R., Dash, R., Majhi, B., & Prasad, V.** (2017). Automated pathological brain detection system: A fast discrete curvelet transform and probabilistic neural network based approach. *Expert Systems with Applications*, 88, 152-164.
- Nielsen, M. A.** (2015). *Neural networks and deep learning* (Vol. 25): Determination press San Francisco, CA, USA.
- Nusbaum, A., Tang, C., Wei, T.-C., Buchsbaum, M. S., & Atlas, S. W.** (2000). Whole-brain diffusion MR histograms differ between MS subtypes. *Neurology*, 54(7), 1421-1427.
- Oh, J., Vidal-Jordana, A., & Montalban, X.** (2018). Multiple sclerosis: clinical aspects. *Current opinion in neurology*, 31(6), 752-759.
- Özkan, İ., & Ülker, E.** (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Palmer, A. J., Colman, S., O'Leary, B., Taylor, B. V., & Simmons, R. D.** (2013). The economic impact of multiple sclerosis in Australia in 2010. *Multiple Sclerosis Journal*, 19(12), 1640-1646.
- Patsopoulos, N. A.** (2018). Genetics of multiple sclerosis: an overview and new directions. *Cold Spring Harbor perspectives in medicine*, 8(7), a028951.
- Paty, D., Oger, J., Kastrukoff, L., Hashimoto, S., Hooge, J., Eisen, A., Eisen, K., Purves, S., Low, M., & Brandejs, V.** (1988). MRI in the diagnosis of MS: a prospective study with comparison of clinical evaluation, evoked potentials, oligoclonal banding, and CT. *Neurology*, 38(2), 180-180.
- Paul, L., Coulter, E. H., Miller, L., McFadyen, A., Dorfman, J., & Mattison, P. G. G.** (2014). Web-based physiotherapy for people moderately affected with Multiple Sclerosis; quantitative and qualitative data from a randomized, controlled pilot study. *Clinical rehabilitation*, 28(9), 924-935.
- Paz-Zulueta, M., Paras-Bravo, P., Cantarero-Prieto, D., Blazquez-Fernandez, C., & Oterino-Duran, A.** (2020). A literature review of cost-of-illness studies on the economic burden of multiple sclerosis. *Multiple sclerosis and related disorders*, 43, 102-162. doi:10.1016/j.msard.2020.102162
- Polman, C. H., Reingold, S. C., Banwell, B., Clanet, M., Cohen, J. A., Filippi, M., Fujihara, K., Havrdova, E., Hutchinson, M., & Kappos, L.** (2011). Diagnostic criteria for multiple sclerosis: 2010 revisions to the McDonald criteria. *Annals of neurology*, 69(2), 292-302.

- Polman, C. H., Reingold, S. C., Edan, G., Filippi, M., Hartung, H. P., Kappos, L., Lublin, F. D., Metz, L. M., McFarland, H. F., & O'Connor, P. W.** (2005). Diagnostic criteria for multiple sclerosis: 2005 revisions to the “McDonald Criteria”. *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society*, 58(6), 840-846.
- Poser, C. M., Paty, D. W., Scheinberg, L., McDonald, W. I., Davis, F. A., Ebers, G. C., Johnson, K. P., Sibley, W. A., Silberberg, D. H., & Tourtellotte, W. W.** (1983). New diagnostic criteria for multiple sclerosis: guidelines for research protocols. *Annals of Neurology: Official Journal of the American Neurological Association and the Child Neurology Society*, 13(3), 227-231.
- Ragonese, P., Aridon, P., Salemi, G., D'amelio, M., & Savettieri, G.** (2008). Mortality in multiple sclerosis: a review. *European Journal of Neurology*, 15(2), 123-127.
- Ransohoff, R. M., Hafler, D. A., & Lucchinetti, C. F.** (2015). Multiple sclerosis—a quiet revolution. *Nature Reviews Neurology*, 11(3), 134-142.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G.-Z.** (2016). Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.
- Ravnik, D., Jerman, T., Pernuš, F., Likar, B., & Špiclin, Ž.** (2018). Dataset variability leverages white-matter lesion segmentation performance with convolutional neural network. *Medical Imaging 2018: Image Processing*.
- Relan, K.** (2019). Beginning with Flask *Building REST APIs with Flask* (pp. 1-26): Springer.
- Ren, S., He, K., Girshick, R., & Sun, J.** (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28, 91-99.
- Reynolds, R., Roncaroli, F., Nicholas, R., Radotra, B., Gveric, D., & Howell, O.** (2011). The neuropathological basis of clinical progression in multiple sclerosis. *Acta neuropathologica*, 122(2), 155-170.
- Rolak, L. A., & Fleming, J. O.** (2007). The differential diagnosis of multiple sclerosis. *The neurologist*, 13(2), 57-72.
- Ronneberger, O., Fischer, P., & Brox, T.** (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*.

- Roura, E., Oliver, A., Cabezas, M., Valverde, S., Pareto, D., Vilanova, J. C., Ramió-Torrentà, L., Rovira, À., & Lladó, X.** (2015). A toolbox for multiple sclerosis lesion segmentation. *Neuroradiology*, *57*(10), 1031-1043.
- Rovira, À., & León, A.** (2008). MR in the diagnosis and monitoring of multiple sclerosis: an overview. *European journal of radiology*, *67*(3), 409-414.
- Rush, C. A., MacLean, H. J., & Freedman, M. S.** (2015). Aggressive multiple sclerosis: proposed definition and treatment algorithm. *Nature Reviews Neurology*, *11*(7), 379-389.
- Ruskó, L., Bekes, G., & Fidrich, M.** (2009). Automatic segmentation of the liver from multi- and single-phase contrast-enhanced CT images. *Medical image analysis*, *13*(6), 871-882.
- SadeghiBakhi, M., Pourreza, H., & Mahyar, H.** (2022). Multiple Sclerosis Lesions Segmentation using Attention-Based CNNs in FLAIR Images. *arXiv preprint arXiv:2201.01832*.
- Santiago Rodrigo, L. D., Sánchez Morla, E. M., Ortiz del Castillo, M., López Guillén, M. E., Amo Usanos, C., Alonso Rodríguez, M. C., Barea Navarro, R., Cavaliere Ballesta, C., Fernández Rodríguez, A. J., & Boquete Vázquez, L.** (2019). A computer-aided diagnosis of multiple sclerosis based on mfVEP recordings.
- Sarigül, M., Ozyildirim, B. M., & Avcı, M.** (2019). Differential convolutional neural network. *Neural Networks*, *116*, 279-287.
- Schmidt, P., Gaser, C., Arsic, M., Buck, D., Förchler, A., Berthele, A., Hoshi, M., Ilg, R., Schmid, V. J., & Zimmer, C.** (2012). An automated tool for detection of FLAIR-hyperintense white-matter lesions in multiple sclerosis. *NeuroImage*, *59*(4), 3774-3783.
- Scolding, N.** (2001). The differential diagnosis of multiple sclerosis. *Journal of Neurology, Neurosurgery & Psychiatry*, *71*(suppl 2), ii9-ii15.
- Shanmuganathan, M., Almutairi, S., Aborokbah, M. M., Ganesan, S., & Ramachandran, V.** (2020). Review of advanced computational approaches on multiple sclerosis segmentation and classification. *IET Signal Processing*, *14*(6), 333-341.
- Shelhamer, E., Long, J., & Darrell, T.** (2016). Fully convolutional networks for semantic segmentation. *IEEE transactions on pattern analysis and machine intelligence*, *39*(4), 640-651.
- Shiee, N., Bazin, P.-L., & Pham, D. L.** (2008). Multiple sclerosis lesion segmentation using statistical and topological atlases. *Grand Challenge Work.: Mult. Scler. Lesion Segm. Challenge*, 1-10.
- Shoeibi, A., Khodatars, M., Jafari, M., Moridian, P., Rezaei, M., Alizadehsani, R., Khozimeh, F., Gorriz, J. M., Heras, J., & Panahiazar, M.** (2021). Applications of deep

learning techniques for automated multiple sclerosis detection using magnetic resonance imaging: A review. *Computers in Biology and Medicine*, 136, 104697.

**Singh, P., & Manure, A.** (2020). Introduction to tensorflow 2.0 *Learn TensorFlow 2.0* (pp. 1-24): Springer.

**Sintzel, M. B., Rametta, M., & Reder, A. T.** (2018). Vitamin D and multiple sclerosis: a comprehensive review. *Neurology and therapy*, 7(1), 59-85.

**Solari, A., Motta, A., Mendozzi, L., Pucci, E., Forni, M., Mancardi, G., & Pozzilli, C.** (2004). Computer-aided retraining of memory and attention in people with multiple sclerosis: a randomized, double-blind controlled trial. *Journal of the neurological sciences*, 222(1-2), 99-104.

**Souplet, J.-C., Lebrun, C., Ayache, N., & Malandain, G.** (2008). An automatic segmentation of T2-FLAIR multiple sclerosis lesions.

**Styner, M., Lee, J., Chin, B., Chin, M., Commowick, O., Tran, H., Markovic-Plese, S., Jewells, V., & Warfield, S.** (2008). 3D segmentation in the clinic: A grand challenge II: MS lesion segmentation. *Midas Journal*, 2008, 1-6.

**Subbanna, N., Shah, M., Francis, S., Narayanan, S., Collins, D., Arnold, D., & Arbel, T.** (2009). MS lesion segmentation using Markov Random Fields. *proceedings of international Conference on medical image computing and computer assisted intervention, London, UK*.

**Sun, M., Song, Z., Jiang, X., Pan, J., & Pang, Y.** (2017). Learning pooling for convolutional neural network. *Neurocomputing*, 224, 96-104.

**Taha, A. A., & Hanbury, A.** (2015). Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC medical imaging*, 15(1), 1-28.

**Tallner, A., Pfeifer, K., & Mäurer, M.** (2016). Web-based interventions in multiple sclerosis: the potential of tele-rehabilitation. *Therapeutic advances in neurological disorders*, 9(4), 327-335.

**Talo, M., Yildirim, O., Baloglu, U. B., Aydin, G., & Acharya, U. R.** (2019). Convolutional neural networks for multi-class brain disease detection using MRI images. *Computerized Medical Imaging and Graphics*, 78, 101673.

**Targ, S., Almeida, D., & Lyman, K.** (2016). Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*.

**Tedeschi, G., Lavorgna, L., Russo, P., Prinster, A., Dinacci, D., Savettieri, G., Quattrone, A., Livrea, P., Messina, C., & Reggio, A.** (2005). Brain atrophy and lesion load in a large population of patients with multiple sclerosis. *Neurology*, 65(2), 280-285.

- Thompson, A., Banwell, B., Barkhof, F., Carroll, W., Coetzee, T., Comi, G., Correale, J., Fazekas, F., Filippi, M., Freedman, M., Fujihara, K., Galetta, S., Hartung, H., Kappos, L., Lublin, F., Marrie, R., Miller, A., Miller, D., Montalban, X., Mowry, E., Sorensen, P., Tintore, M., Traboulsee, A., Trojano, M., Uitdehaag, B., Vukusic, S., Waubant, E., Weinshenker, B., Reingold, S., & Cohen, J.** (2018). Diagnosis of multiple sclerosis: 2017 revisions of the McDonald criteria. *The Lancet Neurology*, *17*(2), 162-173. doi:10.1016/S1474-4422(17)30470-2
- Till, C., Deotto, A., Tipu, V., Sled, J. G., Bethune, A., Narayanan, S., Arnold, D. L., & Banwell, B. L.** (2011). White matter integrity and math performance in pediatric multiple sclerosis: a diffusion tensor imaging study. *Neuroreport*, *22*(18), 1005-1009.
- Toğrol, E., & Demir, S.** (2016). Multipl Skleroz Ve İlişkili Hastalıkların Tanı Ve İzleminde Manyetik Rezonans İnceleme İlkeleri Manyetik Rezonans Görüntüleme (MRG) In İ. Çevik (Ed.), *Multipl Skleroz Tanı Ve Tedavi Kılavuzu*
- Ünal, A., Mavioglu, H., Altunrende, B., Kale İcen, N., & Ergün, U.** (2018). Multipl Sklerozda Tanı ve Ayırıcı Tanı. In H. Efendi & D. Yandım Kuşcu (Eds.), *Multipl Skleroz Tanı Ve Tedavi Kılavuzu: Galenos Yayınevi.*
- Valcarcel, A. M., Linn, K. A., Vandekar, S. N., Satterthwaite, T. D., Muschelli, J., Calabresi, P. A., Pham, D. L., Martin, M. L., & Shinohara, R. T.** (2018). MIMoSA: an automated method for intermodal segmentation analysis of multiple sclerosis brain lesions. *Journal of Neuroimaging*, *28*(4), 389-398.
- Valverde, S., Cabezas, M., Roura, E., González-Villà, S., Pareto, D., Vilanova, J. C., Ramió-Torrentà, L., Rovira, À., Oliver, A., & Lladó, X.** (2017). Improving automated multiple sclerosis lesion segmentation with a cascaded 3D convolutional neural network approach. *NeuroImage*, *155*, 159-168.
- Van Eck, N. J., & Waltman, L.** (2013). VOSviewer manual. *Leiden: Univeriteit Leiden*, *1*(1), 1-53.
- Van Leemput, K., Maes, F., Vandermeulen, D., Colchester, A., & Suetens, P.** (2001). Automated segmentation of multiple sclerosis lesions by model outlier detection. *IEEE transactions on medical imaging*, *20*(8), 677-688.
- Veloso, M.** (2014). A web-based decision support tool for prognosis simulation in multiple sclerosis. *Multiple sclerosis and related disorders*, *3*(5), 575-583.
- Wadhwa, A., Bhardwaj, A., & Verma, V. S.** (2019). A review on brain tumor segmentation of MRI images. *Magnetic resonance imaging*, *61*, 247-259.

- Wang, J., Liu, M., Zhang, C., Xu, H., Zhang, L., & Zhao, Y.** (2020). An adaptive sparse Bayesian model combined with probabilistic label fusion for multiple sclerosis lesion segmentation in brain MRI. *Future Generation Computer Systems*, *105*, 695-704.
- Wang, S.-H., Tang, C., Sun, J., Yang, J., Huang, C., Phillips, P., & Zhang, Y.-D.** (2018). Multiple sclerosis identification by 14-layer convolutional neural network with batch normalization, dropout, and stochastic pooling. *Frontiers in neuroscience*, *12*.
- 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), 1560-1569.
- Weimer, D., Scholz-Reiter, B., & Shpitalni, M.** (2016). Design of deep convolutional neural network architectures for automated feature extraction in industrial inspection. *CIRP Annals*, *65*(1), 417-420.
- Wu, H., & Gu, X.** (2015). Towards dropout training for convolutional neural networks. *Neural Networks*, *71*, 1-10.
- Wu, J.-N.** (2016). Compression of fully-connected layer in neural network by kronecker product. *2016 Eighth International Conference on Advanced Computational Intelligence (ICACI)*.
- Wu, X., & Lopez, M.** (2017). Multiple sclerosis slice identification by haar wavelet transform and logistic regression. *Advances in Materials, Machinery, Electrical Engineering (AMMEE 2017)*.
- Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K.** (2017). Aggregated residual transformations for deep neural networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Yamamoto, D., Arimura, H., Kakeda, S., Magome, T., Yamashita, Y., Toyofuku, F., Ohki, M., Higashida, Y., & Korogi, Y.** (2010). Computer-aided detection of multiple sclerosis lesions in brain magnetic resonance images: False positive reduction scheme consisted of rule-based, level set method, and support vector machine. *Computerized Medical Imaging and Graphics*, *34*(5), 404-413.
- Yıldırım, M. S., & Dandil, E.** (2021). DeepMSWeb: A Web-Based Decision Support System via Deep Learning for Automatic Detection of MS Lesions. *2021 2nd International Informatics and Software Engineering Conference (IISEC)*.
- Yıldırım, M. S., & Dandil, E.** (2020). Automatic detection of multiple sclerosis lesions using Mask R-CNN on magnetic resonance scans. *IET Image Processing*, *14*(16), 4277-4290.

- Yıldırım, M. S., & Dandil, E.** (2021). Automated Multiple Sclerosis Lesion Segmentation on MR Images via Mask R-CNN. *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*.
- Zahoor, I., Rui, B., Khan, J., Datta, I., & Giri, S.** (2021). An emerging potential of metabolomics in multiple sclerosis: a comprehensive overview. *Cell Mol Life Sci*, 78(7), 3181-3203. doi:10.1007/s00018-020-03733-2
- 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*, 55.
- Zhang, Y.-D., Pan, C., Sun, J., & Tang, C.** (2018). Multiple sclerosis identification by convolutional neural network with dropout and parametric ReLU. *Journal of computational science*, 28, 1-10.
- Zhang, Y., Lu, S., Zhou, X., Yang, M., Wu, L., Liu, B., Phillips, P., & Wang, S.** (2016). Comparison of machine learning methods for stationary wavelet entropy-based multiple sclerosis detection: decision tree, k-nearest neighbors, and support vector machine. *Simulation*, 92(9), 861-871.
- Zhao, Y., Guo, S., Luo, M., Shi, X., Bilello, M., Zhang, S., & Li, C.** (2018). A level set method for multiple sclerosis lesion segmentation. *Magnetic resonance imaging*, 49, 94-100.
- Zou, K. H., Warfield, S. K., Bharatha, A., Tempany, C. M., Kaus, M. R., Haker, S. J., Wells III, W. M., Jolesz, F. A., & Kikinis, R.** (2004). Statistical validation of image segmentation quality based on a spatial overlap index1: scientific reports. *Academic radiology*, 11(2), 178-189.