

**T.C.**  
**İSTANBUL OKAN ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**  
**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**  
**YÜKSEK LİSANS PROGRAMI**

**İzzet ÖZEN**

**BEYNİN BEYAZ CEVHER BÖLGESİNDEKİ YÜKSEK**  
**YOĞUNLUKLU ALANLARIN OLUŞUM VE**  
**YAYILIMINA YÖNELİK UZMAN SİSTEM TASARIMI**  
**VE GERÇEKLENMESİ**

**İSTANBUL, Mart 2022**

**T.C.**  
**İSTANBUL OKAN ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**  
**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**  
**YÜKSEK LİSANS PROGRAMI**

**İzzet ÖZEN**

**BEYNİN BEYAZ CEVHER BÖLGESİNDEKİ YÜKSEK**  
**YOĞUNLUKLU ALANLARIN OLUŞUM VE**  
**YAYILIMINA YÖNELİK UZMAN SİSTEM TASARIMI**  
**VE GERÇEKLENMESİ**

**DANIŞMAN**

Prof.Dr. Bekir Tefik AKGÜN

**İSTANBUL, Mart 2022**

BEYNİN BEYAZ CEVHER BÖLGESİNDEKİ YÜKSEK YOĞUNLUKLU  
ALANLARIN OLUŞUM VE YAYILIMINA YÖNELİK UZMAN SİSTEM  
TASARIMI VE GERÇEKLENMESİ

Yüksek Lisans Tezi

İZZET ÖZEN

tarafından

İSTANBUL OKAN ÜNİVERSİTESİ

Bilgisayar Mühendisliği Anabilim Dalına

YÜKSEK LİSANS

derecesi şartını sağlamak için sunulmuştur.

---

Danışman  
Prof. Dr. Bekir Tevfik Akgün

---

Üye  
Doç. Dr. Pınar Yıldırım

---

Üye  
Dr. Öğr. Üyesi Füsun Er

Mart 2022

Program: Bilgisayar Mühendisliği

## KISA ÖZET

### BEYNİN BEYAZ CEVHER BÖLGESİNDEKİ YÜKSEK YOĞUNLUKLU ALANLARIN OLUŞUM VE YAYILIMINA YÖNELİK UZMAN SİSTEM TASARIMI VE GERÇEKLENMESİ

Canlı bir insanın beynindeki rahatsızlıkları veya anormallikleri tespit etmek için kullanılan en yaygın ve en temel tetkik yöntemi Manyetik Rezonans Görüntülemedir (MRG). MRG'den elde edilen görüntülerde beyin beyaz cevher denilen bölgesinde birtakım yüksek yoğunluklu alanlar, başka bir deyişle lezyonlar görülebilmektedir. Bu lezyonlar çoğunlukla ileri yaştaki bireylerde görülmekle beraber her yaş grubundan insanda da görülebilir. Beyaz cevherdeki bu lezyonlar beyindeki küçük damar hastalığının bir belirtisi olarak kabul edilmektedir. Bu lezyonların inme, Alzaymır, Multipl Skleroz (MS), Migren, Hipertansif Arteryopati gibi birçok klinik bozukluk ile ilişkisini ortaya koyan çalışmalar bulunmaktadır. Zaman içerisinde beyinde farklı noktalarda yeni lezyon oluşumları veya mevcut lezyonların yayılması ile lezyon hacminde artış görülebilmektedir.

Hastalara ait farklı zaman dilimlerinde çekilmiş çeşitli türdeki görüntüler uzman radyologlar tarafından incelenip, diğer klinik bulgularla birlikte değerlendirilerek hastalığın tanı, tedavi ve takibinde kullanılmaktadır.

Bu tezin amacı lezyon oluşumu hakkında öngörude bulunmayı sağlayan bir sistem geliştirmektir. Bu çalışmada; bir grup hastanın farklı zaman dilimlerinde çekilmiş ve araştırmacıların kullanımına sunulmuş beyin Manyetik Rezonans (MR) görüntüleri ön işlemlerden geçiriliyor. Elde edilen işlenmiş görüntülerden seçilen pikseller ve kesin

referans piksellerin merkezde olduđu görüntü yamaları ile bir veri seti oluşturuluyor. Bu veri seti üzerinde derin öğrenme yöntemleri kullanarak yapay bir sinir ağı eğitiliyor. Ağın çıktısı olarak elde edilen model dosyası geliştirilen web tabanlı test uygulamasında kullanılarak bir MR görüntüsü üzerinde nerede lezyon oluşacağı tahmin edip işaretleniyor. Sonuç olarak önerdiğimiz bu yöntem bir uzmandan bağımsız tespit yapmakta yeterli olmamakla beraber uzman doktorların teşhis ve tedavisine destek sağlayacaktır.

Anahtar Kelimeler: Beyin, Manyetik Rezonans Görüntüleme (MRG), Beyaz Cevher, Lezyon, Yüksekyoğunluklu Alanlar, Derin Öğrenme

# ABSTRACT


## EXPERT SYSTEM DESIGN AND IMPLEMENTATION FOR THE OCCURRENCE AND SPREAD OF HYPERINTENSE AREAS IN THE WHITE MATTER REGION OF THE BRAIN

Magnetic Resonance Imaging (MRI) is commonly used in-vivo imaging of the human brain to detect disorders or abnormalities in the brain. In the images obtained from MRI, some hyperintense areas, in other words, lesions can be seen in the white matter region of the brain. Although these lesions are mostly seen in elderly individuals, they can also be seen in people of all age groups. These lesions in the white matter are considered a manifestation of small vessel disease in the brain. There are studies showing the relationship of these lesions with many clinical disorders such as stroke, Alzheimer's, Multiple Sclerosis (MS), Migraine, and Hypertensive Arteriopathy. In time, the lesion volume may increase with the occurrence of new lesions at different locations in the brain or the spread of existing lesions.

Various types of images taken at different time periods of patients are analyzed by expert radiologists, evaluated together with other clinical findings, and used in the diagnosis, treatment and follow-up of the disease.

The aim of this thesis is to develop a system that allows to predict the lesion occurrence. In this study; We are preprocessing brain Magnetic Resonance (MR) images of a group of patients taken at different time periods and made available to researchers. We are generating dataset from image patches that ground-truth pixels and

selected pixels from processed images are in the center of the patch. We train an artificial neural network using deep learning methods on this dataset. By using the model file that we obtained as the output of the network in the web-based application we developed, we predict and mark where a lesion will occur on an MR image. As a result, this method we proposed is not sufficient to make an independent determination from a specialist, but it will support the diagnosis and treatment of specialist doctors.



Keywords: Brain, Magnetic Resonance Imaging (MRI), White Matter, Lesion, Hyperintense Fields, Deep Learning

I would like to thank to my advisor Mr. Prof. Dr. Bekir Tefvik Akgün for his support with his experience and knowledge. Also thank to my wife Özgür, my children Havin Göksu and Arin Cihan for their moral support.

## TEŞEKKÜR

Bu çalışmada bilgi ve tecrübesi ile yanımda olan danışman hocam Sn. Prof. Dr. Bekir Tevfik Akgün'e, manevi desteklerini esirgemeyen eşim Özgür'e, çocuklarım Havin Göksu ve Arin Cihan'a teşekkür ederim.



# İÇİNDEKİLER

|                                                               |      |
|---------------------------------------------------------------|------|
| TABLO LİSTESİ.....                                            | IV   |
| ŞEKİL LİSTESİ.....                                            | VIII |
| KISALTMALAR.....                                              | XII  |
| I. GİRİŞ.....                                                 | 1    |
| 1.1. BAŞLICA TIBBİ GÖRÜNTÜLEME TEKNİKLERİ .....               | 2    |
| 1.1.1. Ultrasonografi .....                                   | 2    |
| 1.1.2. Röntgen .....                                          | 3    |
| 1.1.3. Bilgisayarlı Tomografi.....                            | 3    |
| 1.1.4. Manyetik Rezonans Görüntüleme.....                     | 5    |
| 1.1.4.1. MRG Sekansları .....                                 | 6    |
| 1.2. BEYNİN BEYAZ CEVHER BÖLGESİNDEKİ YÜKSEK YOĞUNLUKLAR..... | 7    |
| 1.3. BEYİN MR GÖRÜNTÜLERİNDE DERİN ÖĞRENME ÇALIŞMALARI .....  | 10   |
| II. DERİN ÖĞRENME.....                                        | 12   |
| 2.1. DERİN ÖĞRENMENİN TARİHÇESİ .....                         | 12   |
| 2.2. EVRİŞİMLİ SINIR AĞLARI .....                             | 14   |
| 2.2.1. Evrişimli Sinir Ağı Katmanları .....                   | 15   |
| 2.2.2. Gizli Katmanlar.....                                   | 16   |
| 2.2.3. İleri ve Geri Yayılım .....                            | 16   |
| 2.2.4. Transfer Öğrenme .....                                 | 21   |
| 2.2.5. VGG16 Modeli .....                                     | 21   |
| III. MS HASTALARI MR GÖRÜNTÜ VERİ SETİ.....                   | 23   |
| 3.1. VERİ SETİNİN İÇERİĞİ.....                                | 23   |
| IV. UZMAN SİSTEM TASARIMI .....                               | 29   |
| 4.1. KULLANILAN ARAÇLAR .....                                 | 29   |

|                                                                                                                             |    |
|-----------------------------------------------------------------------------------------------------------------------------|----|
| 4.2. VERİ SETİNİN YAPAY SINIR AĞI İÇİN HAZIRLANMASI .....                                                                   | 30 |
| 4.2.1. Verileri Saklama Biçimi .....                                                                                        | 30 |
| 4.2.2. Beyaz Cevher Lezyon Değişim Maskelerinin Saklanması.....                                                             | 31 |
| 4.2.3. Beyaz Cevher Lezyon Değişim Maskelerindeki KR Koordinatların<br>Saklanması .....                                     | 32 |
| 4.2.4. Axial Düzlemdeki T2 Ağırlıklı MR Görüntülerinin Saklanması .....                                                     | 33 |
| 4.2.5. Kesitlerdeki Beyin Alanlarının Konturlarının Hesaplanması .....                                                      | 33 |
| 4.2.6. Kesitlerin Normalize Edilmesi.....                                                                                   | 34 |
| 4.2.7. Normalize Edilmiş Kesitlerden KR Koordinatları Merkezine Alan<br>Görüntü Yamalarının Üretilmesi .....                | 35 |
| 4.2.8. KR-Değil Görüntü Yamalarının Alınması.....                                                                           | 36 |
| 4.3. YAPAY SINIR AĞININ EĞİTİMİ.....                                                                                        | 38 |
| 4.4. WEB TABANLI TEST UYGULAMASI .....                                                                                      | 45 |
| 4.5. WEB TABANLI TEST UYGULAMASININ ÇIKTILARININ RENKLENDİRİLMESİ.....                                                      | 45 |
| V. UZMAN SİSTEMİN İYİLEŞTİRİLMESİNE YÖNELİK ÖNERİLER .....                                                                  | 48 |
| 5.1. DENEK SAYISINDAKİ DEĞİŞİMİN ETKİSİ.....                                                                                | 48 |
| 5.2. GÖRÜNTÜ YAMALARININ NORMALIZE EDİLMESİNİN ETKİSİ.....                                                                  | 49 |
| 5.3. GÖRÜNTÜ YAMALARININ FARKLI YÖNTEMLERLE NORMALIZE EDİLMESİNİN<br>ETKİSİ   51                                            |    |
| 5.4. VERİ SETİNDEKİ EĞİTİM, DOĞRULAMA VE TEST ORANLARINDAKİ DEĞİŞİMİN<br>ETKİSİ 52                                          |    |
| 5.5. DEVİR (EPOCH) SAYISININ ARTIRILMASININ ETKİSİ .....                                                                    | 53 |
| 5.6. NON-WMH VERİ SETİNİ OLUŞTURMAK İÇİN RASTGELE SEÇİLEN PİKSELLER<br>ARASINA BELİRLİ BİR MESAFE KONULMASININ ETKİSİ ..... | 55 |
| 5.7. GÖRÜNTÜ YAMALARINI BÜYÜTÜRKEN KULLANILAN FARKLI YÖNTEMLERİN<br>ETKİLERİ .....                                          | 56 |
| 5.8. AYNI VERİ SETİ İLE VGG16 YERINE RESNET50 KULLANMANIN ETKİSİ.....                                                       | 57 |
| 5.9. YAMA BOYUTLARINI FATPIXEL YÖNTEMYİLE BÜYÜTMENİN ETKİSİ.....                                                            | 57 |
| 5.10. LINEAR VEYA PIECEWISE-LINEAR1 NORMALİZASYON YÖNTEMİ KULLANMANIN<br>ETKİSİ 58                                          |    |

|                                                                                                                                         |    |
|-----------------------------------------------------------------------------------------------------------------------------------------|----|
| 5.11. PIECEWISE-LINEAR1 NORMALİZASYON YÖNTEMİNDE YAMA BOYUTUNU<br>BÜYÜTME YÖNTEMLERİNİN ETKİSİ .....                                    | 62 |
| 5.12. PIECEWISE-LINEAR1 İLE PIECEWISE-LINEAR2 NORMALİZASYON<br>YÖNTEMLERİNİN KARŞILAŞTIRMASI.....                                       | 62 |
| 5.13. WEB TABANLI TEST UYGULAMASIYLA TEST İÇİN KULLANILAN VERİDEKİ<br>DEĞİŞİKLİĞİN ETKİSİ .....                                         | 64 |
| 5.14. YAMA BOYUTUNDAKİ DEĞİŞİKLİĞİN ETKİSİ.....                                                                                         | 67 |
| 5.15. PIECEWISE-LINEAR1 İLE TRESHOLD1 NORMALİZASYON YÖNTEMLERİNİN<br>KARŞILAŞTIRMASI .....                                              | 68 |
| 5.16. YAMA BOYUTU 17x17 İKEN VERİ SETİ ORANINDAKİ VE NORMALİZASYON<br>YÖNTEMİNDEKİ DEĞİŞİMİN ETKİLERİ .....                             | 69 |
| 5.17. İKİ VE ÜÇ PARÇALI NORMALİZASYON YÖNTEMLERİNİN ETKİSİ.....                                                                         | 71 |
| 5.18. SIGMOID NORMALİZASYON YÖNTEMİNİN ETKİSİ.....                                                                                      | 74 |
| 5.19. NORMALİZASYONUN YAMA İÇİ HISTOGRAM KULLANILARAK YAPILMASI İLE<br>KESİT İÇİ HISTOGRAM KULLANILARAK YAPILMASI DURUMUNUN ETKİSİ..... | 75 |
| VI. ÖNERİLEN YÖNTEMLERİN DEĞERLENDİRİLMESİ .....                                                                                        | 79 |
| VII. SONUÇLAR .....                                                                                                                     | 86 |
| KAYNAKLAR .....                                                                                                                         | 88 |
| ÖZGEÇMİŞ .....                                                                                                                          | 93 |

## TABLO LİSTESİ

|              |                                                                                                                                                     |    |
|--------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tablo III.1. | Veri setindeki tüm hastaların MR görüntülerinin sayısı .....                                                                                        | 28 |
| Tablo IV.1.  | Görüntü, hasta ve kesit bilgisini ilişkili bir şekilde saklamak için<br>kullanılan .npz formatındaki dosya içeriklerinin temsili gösterimi<br>..... | 31 |
| Tablo V.1.   | Denek sayısındaki değişimin test veri seti üzerindeki etkisi .....                                                                                  | 49 |
| Tablo V.2.   | Görüntü yamalarının normalize edilmesinin test veri seti<br>üzerindeki etkisi .....                                                                 | 50 |
| Tablo V.3.   | Normalizasyon yöntemindeki değişimin test veri seti üzerindeki<br>etkisi.....                                                                       | 52 |
| Tablo V.4.   | Veri setindeki oranların değişimin test verisi üzerindeki etkisi.....                                                                               | 53 |
| Tablo V.5.   | Eğitimdeki devir sayısındaki değişimin test verisi üzerindeki<br>etkisi .....                                                                       | 53 |
| Tablo V.6.   | Rastgele üretilen merkez koordinatlar arası mesafe kontrolünün<br>test verisi üzerindeki etkisi.....                                                | 56 |
| Tablo V.7.   | Görüntü yamalarını büyütürken kullanılan yöntemin doğruluğa<br>etkisi.....                                                                          | 56 |
| Tablo V.8.   | Devir sayısının 30 olması durumundaki doğruluk değerleri.....                                                                                       | 57 |
| Tablo V.9.   | Devir sayısının 50 olması durumundaki doğruluk değerleri.....                                                                                       | 57 |
| Tablo V.10.  | Kullanılan modelin test verisi üzerindeki etkisi.....                                                                                               | 57 |
| Tablo V.11.  | Diğer Bütün koşullar aynı iken kullanılan yama büyütme<br>yönteminin test verisi üzerindeki etkisi .....                                            | 58 |

|             |                                                                                                                               |    |
|-------------|-------------------------------------------------------------------------------------------------------------------------------|----|
| Tablo V.12. | Kullanılan iki farklı normalizasyon yönteminin test verisi üzerindeki etkisi .....                                            | 60 |
| Tablo V.13. | Piecewise-Linear1 normalizasyon yönteminde yama büyütme yönteminin test verisi üzerindeki etkisi. ....                        | 62 |
| Tablo V.14. | Piecewise-Linear1 normalizasyon yönteminde yama büyütme yönteminin web tabanlı test uygulamasındaki etkisi. ....              | 62 |
| Tablo V.15. | Piecewise-Linear1 ve Piecewise-Linear2 normalizasyon yöntemlerinin test verisi üzerindeki etkisi .....                        | 63 |
| Tablo V.16. | Piecewise-Linear1 ve Piecewise-Linear2 normalizasyon yöntemlerinin web tabanlı test uygulamasındaki etkisi .....              | 64 |
| Tablo V.17. | Model ve web tabanlı test uygulaması için kullanılacak verilerdeki değişikliğin test verisi üzerindeki etkisi .....           | 65 |
| Tablo V.18. | Model ve web tabanlı test uygulaması için kullanılacak verilerdeki değişikliğin web tabanlı test uygulamasındaki etkisi ..... | 65 |
| Tablo V.19. | Modelin eğitimi için kullanılan yama boyutu değişikliğinin test verisi üzerindeki etkisi .....                                | 67 |
| Tablo V.20. | Modelin eğitimi için kullanılan yama boyutu değişikliğinin web tabanlı test uygulamasındaki etkisi .....                      | 67 |
| Tablo V.21. | Piecewise-Linear1 ve Treshold1 normalizasyon yöntemlerinin test verisi üzerindeki etkisi.....                                 | 68 |
| Tablo V.22. | Piecewise-Linear1 ve Treshold1 normalizasyon yöntemlerinin web tabanlı test uygulamasındaki etkisi .....                      | 68 |
| Tablo V.23. | WMH, Non-WMH oranındaki değişimin test verisi üzerindeki etkisi.....                                                          | 69 |

|             |                                                                                                                                    |    |
|-------------|------------------------------------------------------------------------------------------------------------------------------------|----|
| Tablo V.24. | WMH, Non-WMH oranındaki deęişimin web tabanlı test uygulamasındaki etkisi.....                                                     | 70 |
| Tablo V.25. | WMH, Non-WMH oranın $\frac{1}{2}$ olduęu durumda normalizasyon yöntemindeki deęişimin test verisi üzerindeki etkisi.....           | 70 |
| Tablo V.26. | WMH, Non-WMH oranın $\frac{1}{2}$ olduęu durumda normalizasyon yöntemindeki deęişimin web tabanlı test uygulamasındaki etkisi..... | 71 |
| Tablo V.27. | 2 parçalı ve 3 parçalı normalizasyon yöntemlerinin test verisi üzerindeki etkileri .....                                           | 73 |
| Tablo V.28. | 2 parçalı ve 3 parçalı normalizasyon yöntemlerinin web tabanlı test uygulamasındaki etkisi.....                                    | 73 |
| Tablo V.29. | Sigmoid normalizasyon yöntemlerinin test verisi üzerindeki etkisi.....                                                             | 75 |
| Tablo V.30. | Sigmoid normalizasyon yönteminin web tabanlı test uygulamasındaki etkisi.....                                                      | 75 |
| Tablo V.31. | Normalizasyon için kullanılan bölgenin test verisi üzerindeki etkisi.....                                                          | 76 |
| Tablo V.32. | Normalizasyon için kullanılan bölgenin web tabanlı test uygulamasındaki etkisi.....                                                | 76 |
| Tablo V.33. | Piecewise-Linear1 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin test verisi üzerindeki etkileri .....          | 77 |
| Tablo V.34. | Piecewise-Linear1 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin web tabanlı test uygulamasındaki etkisi.....   | 77 |

|             |                                                                                                                                                                                              |    |
|-------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tablo V.35. | Piecewise-Linear2 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin test verisi üzerindeki etkileri.....                                                                     | 78 |
| Tablo V.36. | Piecewise-Linear2 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin web tabanlı test uygulamasındaki etkisi.....                                                             | 78 |
| Tablo VI.1. | Tüm ikili denemelerin ağıın eğitimi sırasındaki test accuracy yönünden karşılaştırmaları yanında, web tabanlı test uygulamasındaki çıktıların F1 ve accuracy yönünden karşılaştırmaları..... | 85 |

## ŞEKİL LİSTESİ

|              |                                                                                                                                                                            |    |
|--------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil II.1.  | ESA katmanlarının temsili görünümü. ....                                                                                                                                   | 15 |
| Şekil II.2.  | Bir yapay sinir ağı hücresinin (a) ve biyolojik sinir hücresinin (b) temsili gösterimleri .....                                                                            | 17 |
| Şekil II.3.  | VGG16 evrişimli sinir ağı modelinin mimarisi. ....                                                                                                                         | 22 |
| Şekil III.1. | Patient11 isimli hasta için veri setindeki dosya içeriği. ....                                                                                                             | 24 |
| Şekil III.2. | Patient10 isimli hastanın axial düzlemdeki örnek MR görüntüleri.....                                                                                                       | 25 |
| Şekil III.3. | Patient10 isimli hastanın coronal düzlemdeki örnek MR görüntüleri.....                                                                                                     | 26 |
| Şekil III.4. | Patient10 isimli hastanın sagittal düzlemdeki örnek MR görüntüleri.....                                                                                                    | 27 |
| Şekil IV.1.  | patient12 isimli hastanın axial düzlemdeki 25. kesitinde KR alanların görünümü. ....                                                                                       | 32 |
| Şekil IV.2.  | patient12 isimli hastanın axial düzlemdeki 25. Kesitinin görünümü (Matplot görüntüyü ekranda gösterirken otomatik renklendirmiştir. Orjinal görüntü siyah beyazdır).. .... | 33 |
| Şekil IV.3.  | patient4 isimli hastanın 43 numaralı kesiti (solda), görüntü üzerinde hesaplan kontur (ortada) ve kontur koordinatlarının görselleştirilmesi (sağda). ....                 | 34 |
| Şekil IV.4.  | Normalize edilmiş görüntü (solda) ve orjinal görüntü (sağda). ....                                                                                                         | 35 |

|              |                                                                                                                                                                          |    |
|--------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil IV.5.  | Okan Logopatient19 isimli hastanın 24 numaralı kesitindeki y:213, x:176 KR koordinatı merkezine alan 21x21 piksel boyutundaki görüntü yaması.....                        | 36 |
| Şekil IV.6.  | patient11 isimli hastanın 35 numaralı kesitindeki KR pikseller (sağda) ve bu pikselleri merkezine alan kırmızı boyalı yamalar (solda). ....                              | 37 |
| Şekil IV.7.  | patient14 isimli hastanın 28 numaralı kesitindeki y:119, x:68 rastgele belirlenmiş koordinatı merkezine alan 21x21 piksel boyutundaki görüntü yaması.....                | 38 |
| Şekil IV.8.  | Sınıf etiketleri ile beraber örnek görüntü yamaları.....                                                                                                                 | 39 |
| Şekil IV.9.  | Non-WMH sınıfından 48x48 ebatlarına boyutlandırılıp, 3 kanallı hale getirilmiş örnek bir görüntü yaması. ....                                                            | 39 |
| Şekil IV.10. | Transfer öğrenme için kullanılan VGG16 isimli yapay sinir ağının son 4 katmanı hariç diğer katmanları dondurulmuştur.. ....                                              | 40 |
| Şekil IV.11. | Veri çoğaltma işlemi uygulandıktan sonra sınıf bilgisi, en ölçüsü, boy ölçüsü ve kanal sayısı bilgisiyle örnek görüntüler.....                                           | 41 |
| Şekil IV.12. | 30 devirden (epoch) oluşan eğitimde, eğitim ve sınama başarımlarının zamanla değişimi grafiği.....                                                                       | 42 |
| Şekil IV.13. | 30 devirden (epoch) oluşan eğitimde, eğitim ve sınama kaybının zamanla değişimi grafiği.....                                                                             | 43 |
| Şekil IV.14. | Test veri seti ile yapılan tahminlerdeki karışıklığı gösteren Confusion Matrix ve tahminler sonucu hesaplanan doğruluk, hassasiyet, hatırlama ve f1 skor değerleri. .... | 44 |
| Şekil IV.15. | Web tabanlı test uygulamasının veri giriş ekranı.....                                                                                                                    | 45 |

|              |                                                                                                                                                                                                                                                                                                      |    |
|--------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil IV.16. | Patient1 isimli hastanın 29. kesiti için web tabanlı test uygulamasının görsel ve sayısal çıktıları ( a ), Kesite ait işaretlenmiş kesin referans pikseller ( b ), Görsel çıktının yakınlaştırılmış bir parçası ( c ). ....                                                                          | 47 |
| Şekil V.1.   | Float64 tipindeki rastgele örnek görüntü yamalarının 8 bit'e doğrudan dönüştürülmüş hali.....                                                                                                                                                                                                        | 50 |
| Şekil V.2.   | Float64 tipindeki rastgele örnek görüntü yamalarının OpenCV ile normalize edilerek 8 bit'e dönüştürülmüş hali.....                                                                                                                                                                                   | 50 |
| Şekil V.3.   | 20 devirlik bir eğitimde (a) ve 30 devirlik bir eğitimde (b) eğitim ve doğrulama doğruluk değerlerinin devirler boyunca değişimi grafikleri.....                                                                                                                                                     | 54 |
| Şekil V.4.   | 20 devirlik bir eğitimde (a) ve 30 devirlik bir eğitimde (b) eğitim ve doğrulama kayıp değerlerinin devirler boyunca değişimi grafikleri.....                                                                                                                                                        | 54 |
| Şekil V.5.   | Patient10 isimli hastanın axial düzlemdeki 30 numaralı kesitinin görüntüsü (a), bu kesitin gri değerlerini ve karşılık gelen piksel sayılarını gösterir histogramı (b), bu kesitteki KR piksellerin histogramı (c). ....                                                                             | 59 |
| Şekil V.6.   | Patient1 isimli hastanın axial düzlemdeki 29. kesitindeki piksellerin web tabanlı test uygulamasıyla sınıflandırılması sonucu elde edilen görüntüler ve istatistiksel değerler. Linear Normalizasyon yöntemi ile elde edilen çıktı ( a ), Picewise-Linear1 yöntemi ile elde edilen çıktı ( b ). .... | 61 |

- Şekil V.7. Patient20 isimli hastanın axial düzlemdeki 20 numaralı kesitinin web tabanlı test uygulamasıyla değerlendirmesinin sonuçları. 1.Durumun çıktısı (a), 2.Durumun çıktısı (c), 1.Durumun yakınlaştırılmış görüntüsü (b), 2.Durumun yakınlaştırılmış görüntüsü (d).....66
- Şekil V.8. Axail düzlemdeki tüm kesitlerdeki KR piksellerin değerlerinin histogramı. Tepe noktaların gri değerleri sırayla: 95, 293, 491, 689, 887, 1085, 1283, 1481, 1697, 1877, 2075.....72

## KISALTMALAR

**MR** Manyetik Rezonans

**MRG** Manyetik Rezonans Görüntüleme

**MS** Multipl Skleroz

**YSA** Yapay Sinir Ağı

**USG** Ultrasonografi

**BT** Bilgisayarlı Tomografi

**KR** Kesin Referans

**ESA** Evrişimli Sinir Ağı

**GPU** Grafik İşlem Birimi

**BOS** Beyin Omurilik Sıvısı

## I. GİRİŞ

Beyin canlılardaki en gizemli organlardan biri, belki de en karmaşık olanıdır. İnsanoğlu beynin yapısı ve çalışma prensiplerini öğrenmek için çok büyük çabalar saf etmiştir ve halen de etmektedir. Beynin yapısındaki en ufak değişimin kişinin yaşam kalitesine doğrudan ve ciddi etkileri olabilmektedir. Bu nedenle beyinde oluşan ve bilişsel hastalık nedeni olabilecek değişikliklerin anlaşılması ileride geliştirilecek olan tedavilere zemin hazırlayacaktır.

Beyin hassas bir organ olduğundan hayattaki bir kişinin beyindeki anormallikleri gözlemlenmenin günümüzdeki en etkili ve basit yolu görüntüleme teknolojilerini kullanmaktır. Bu görüntüleme teknolojilerinden en yaygın kullanılanı MRG'dir. Uzmanlar MR görüntülerindeki anormallikler ile kişinin bilişsel rahatsızlıkları arasındaki ilişkileri çözmeye çalışmaktadırlar. Günümüzde uzmanlar görüntüler üzerindeki değerlendirmelerini çok büyük oranda çıplak gözle yaptıkları incelemelere dayandırmaktadır.

Bilişim teknolojilerindeki gelişmeler çok yüksek hızda hesaplamalar yapabilen bilgisayarların üretilmesini ve yaygınlaşmasını sağlamıştır. Böylece araştırmacılar bu kaynaklara daha kolay erişebilmiş ve daha fazla kullanabilmiştir. Bu teknolojilerin ışığında görüntülerin yapay zeka ile işlenip, uzman insanların seviyesinde kimi zaman da daha ilerisine geçen sonuçlar vermesi mümkün olmuştur. Özellikle son

yıllarda medikal görüntüler üzerinde Yapay Sinir Ağlarının (YSA) kullanımı oldukça popüler bir çalışma alanı haline gelmiştir.

Bu çalışmada İnme, Alzaymır, MS, Migren, Hipertansif Arteryopati gibi birçok bilişsel hastalıkla ilişkili olduğu düşünülen ve beynin beyaz cevher olarak adlandırılan bölgesinde görülen birtakım lezyonların oluşumu ve ilerleyişinin öngörüsü için makine öğreniminin bir alt kolu olan derin öğrenme yönteminden yararlanılmıştır.

Çalışma sonrasında elde edilen sonuçlarla her ne kadar otonom bir teşhis sistemi sağlanamasa da uzmanların değerlendirmelerine katkı sağlayacak ve onlara hız kazandıracak bir araç olarak değerlendirilebilir.

Bu çalışmada kullanılan araç olan derin öğrenme de aslında beyindeki sinir hücrelerinin çalışma prensibini taklit ederek bilgisayara karmaşık verilerden anlamlı sonuçlar çıkarma ve öğrenme imkanı sunmaktadır. Bu yönüyle beyni taklit eden YSA'lar beyindeki rahatsızlıkların tedavisine katkı sunmak için kullanılmıştır.

### **1.1. Başlıca Tıbbi Görüntüleme Teknikleri**

Radyolojik görüntüleme en basit ifadeyle, canlının vücudunun iç yapısının vücut bütünlüğünü bozmadan dışarıdan çeşitli yöntemler kullanılarak görüntülenmesidir.

Tanısal radyolojide kullanılan dört temel yöntem; Ultrasonografi (USG), Röntgen, Bilgisayarlı Tomografi (BT), ve MRG'dir.

#### **1.1.1. Ultrasonografi**

USG tekniğinde, vücut yüzeyinden gönderilen ses dalgalarının değişik yoğunluktaki dokulardan geri yansımalarının alınıp toplanması ve bundan görüntü elde

edilmesi prensibi vardır. USG görüntülerinde en yüksek yansıma beyaz, en düşük yansıma siyah, ara değerler ise yansıma şiddetine göre değişen gri değerlerle ifade edilir.

USG ile elde edilen iki boyutlu B-mod görüntüler ekrana saniyede 15 ile 60 çerçeve arasındaki hızlarla yansıtılarak gerçek zamanlı hareket izlenimi oluşturulur. Kafatası ve vertebraların oluşturduğu engel nedeniyle yetişkin hastalarda USG ile beyinin standart incelemesi yapılamaz. Ancak anne karnındaki fetüs için yapılan taramalarında, bu dönemde serebral ve medüller gelişimin en kolay incelenebildiği görüntüleme yöntemi USG'dir.

### **1.1.2. Röntgen**

Nobel fizik ödülüne sahip Alman bilim insanı Wilhelm Conrad Röntgen tarafından 1895'te keşfedilen X ışınlarının kullanıldığı tekniktir. X ışınları atomları iyonize edebilecek ve molekküller arası bağları kırabilecek bir etkiye sahiptir. Bu nedenle bu ışınlar canlılara zararlı olan ışınlar sınıfındadır.

Röntgenin çalışma prensibi; Vücuda gönderilen X ışını demetinin değişik dokulardan farklı oranlarda geçmesi ve bu dokular tarafından farklı miktarlarda soğrulması sonrası vücuttan geçip, karşı tarafa ulaşan ışınlardan görüntü elde edilmesine dayanır.

Kemik gibi yapılar X ışınını hava ve yumuşak dokulara kıyasla daha fazla soğurduğu için filmde beyaz görünürken hava siyah görünür. Diğer dokular da yoğunluklarına göre filmde grinin değişen değerleri ile görünür.

### 1.1.3. Bilgisayarlı Tomografi

Nobel ödüllü İngiliz bilim insanı Sir Godfrey Hounsfield tarafından 1972 ve 1973 yılları arasında geliştirilmiştir. Tıbbi görüntülemede kullanılan ilk kesitsel inceleme yöntemidir. Bu yöntemde de röntgende olduğu gibi X ışınları kullandığından iyonizan radyasyon içerir. Başta çekim süresinin kısalığı, düşük maliyeti ve kolay ulaşılabilirliği ile özellikle acil tıbbi değerlendirme açısından önemli bir yere sahiptir.

Çalışma prensibi temelde röntgen ile aynı olmakla beraber BT’de çapı sınırlanıp daraltılarak, röntgen tüpünden ince bir huzme halinde çıkması sağlanan X ışını demetleri kullanılır. Hastadan geçen X ışını fotonları BT dedektörleri tarafından algılanmaktadır. BT cihazında X ışın tüpü ve dedektörler hasta etrafında 360 derece döner. Böylece ışın demeti hastanın bir kesitini birçok değişik açıdan defalarca katederek farklı absorpsiyon örüntüleri oluşturur. Projeksiyon rekonstrüksiyonu olarak isimlendirilen matematiksel işlem ile BT kesiti içindeki her nokta için absorpsiyon değerleri elde edilir. Bilgisayar bu verilerle kesitlerdeki yaklaşık her 1 mm<sup>3</sup> hacimde ne kadar foton tutulduğunu hesaplar. Eğer o birim hacimde çok foton tutulmuşsa bilgisayar o piksele beyaza yakın bir gri tonu, az foton tutulmuşsa, siyaha yakın bir gri tonu verir. Kemik dokusu çok ışın tuttuğundan beyaz, hava çok az ışın tuttuğundan siyah görünür. Yumuşak dokular ise yoğunluklarına göre çeşitli gri tonlarında görünürler [16].

İlaçlı BT çekimlerinde kan beyin bariyerinde yıkım olan bölgeleri belirlemek için iyotlu kontrast maddeler kullanılır. Kan beyin bariyeri yıkılmışsa iyotlu kontrast madde dokuya sızar ve bu şekilde doku kontrastlanır. Kontrastlananmış lezyon bölgesi BT’de hiperdens görünür.

BT ile beynin görüntülenmesi 5 saniyeden kısa sürede bitirilebilir hale gelmiştir. Böylece hareket artefaktlarından etkilenme daha da azalmakta ve hareketli hastalarda bile iyi görüntüler alınabilmektedir.

#### **1.1.4. Manyetik Rezonans Görüntüleme**

MRG, BT gibi bir kesitsel görüntüleme yöntemi olmakla beraber BT'den farklı olarak görüntüleme için X ışınları yerine radyo dalgaları kullanır. Görüntülemeledeki veri kaynağı ise vücutta yoğun olarak bulunan hidrojen atomu çekirdeği olan protonlardır. Hidrojen atomunun çekirdeğinde tek bir proton olduğundan +1 elektrik yükü içerir ve bu nedenle manyetik alan içerisinde bir mikro mıknatıs gibi davranır. Normalde vücuttaki hidrojen atomları rastgele değişik yönlerde manyetik alan vektörleri oluşturur. Hasta MR cihazına girdiğinde hidrojen atomu vektörleri aletin çok güçlü olan mıknatısının oluşturduğu vektör ile aynı yönde birbirlerine paralel dizilerek longitudinal manyetizasyon vektörünü oluştururlar. Aynı yönde dizili bu hidrojen atomlarına, dışardan onların doğal salınım frekansına eşit ve kısa süreli bir RF dalgası gönderildiğinde rezonansa girerler ve ana mıknatıs yönündeki manyetizasyon vektörlerinin longitudinal yöndeki akstan, transvers düzleme doğru sapmasına neden olurlar. RF dalgası kesilince ana manyetik alan vektörünün yönüne tekrar geri dönerler. Bu eski durumlarına tekrar dönme sürecine sönümlenme adı verilir. Sönümlenme sırasında protonlar RF dalgasından almış oldukları enerjiyi tekrar kaybederek ilk hallerine geri dönerler. Bu esnada kaybettikleri enerjiye bağlı oluşan manyetik sinyaller radyo frekans alıcı sargıları tarafından toplanarak MR görüntüleri oluşturulur [16].

Vücuttaki hidrojen dışındaki başka atomlar kullanılarak da MR görüntüler oluşturulabilir. Ancak hidrojen atomu insan vücudunda bolca bulunan su ve yağ

dokularında çok miktarda bulunduğundan ve hidrojenen daha fazla enerji sinyali alınabildiğinden hidrojen tercih edilmektedir.

MRG'nin iyonizan radyasyon içermemesi, beyin dokusuna olan yüksek duyarlılığı ve yüksek anatomik çözünüme gücü önemli avantajları olup, multiplanar görüntü alınabilme özelliği ile diğer tetkiklerden daha üstündür.

Yüksek yumuşak doku çözünürlüğü sayesinde beyindeki beyaz ve gri cevher ayrımı MRG'de çok iyi bir şekilde yapılabilmektedir. Bu nedenlerle beyindeki çeşitli yapısal lezyonları göstermede üstünlüğü BT ile kıyaslanamayacak kadar fazladır.

MRG'nin başlıca dezavantajları ise; uzun çekim süresi nedeniyle çocuklar gibi hareketli hastalarda görüntülerde artefakt oluşması, yüksek maliyetli oluşundan dolayı kolay ulaşılır olmayışı ve kapalı yapısı nedeniyle klostrofobik hastalarda çekim zorluğu yaratmasıdır. Bunlar yanında kap pili, implant gibi vücuttaki yabancı cisimler ile MR cihazına girmek sakınca yartmaktadır.

MR görüntülerinde de USG ve BT'de olduğu gibi, siyah ile beyaz arasındaki gri tonlar kullanılarak görüntü oluşturulur. Beynin MR görüntülerinde beyin dokusuyla aynı derecede enerji sinyali alınan ve dolayısıyla aynı gri tonda görünen dokular “izointens”, daha yüksek sinyal alınarak daha beyaz görünen dokular “hiperintens”, daha düşük sinyal alınarak daha koyu görünen dokular ise “hipointens” olarak görünür.

#### **1.1.4.1. MRG Sekansları**

Sekans görüntülenecek dokunun özelliklerini en iyi biçimde ortaya çıkaracak kontrasta sahip olacak şekilde uygulanacak RF darbeleri, gradyan alanları ve sinyal kayıt zamanları gibi parametrelerin bütününe ifade eder.

T1 ağırlıklı, T2 ağırlıklı ve proton ağırlıklı olmak üzere 3 temel MR puls sekansı vardır. T1 ağırlıklı çekimlerde çok iyi yumuşak doku kontrastı ve uzaysal çözünürlük

sağlandığından anatomik detay yüksektir. T2 ağırlıklı sekanslar ise dokuların karakterizasyonunda ve patolojik sinyal değişikliklerinin saptanmasında daha duyarlıdır. Bu başlıca sekansların yanında Beyin Omurilik Sıvısı (BOS) gibi sıvıları baskılayıp, sıvıların hipointens görünmesini sağlayan FLAIR gibi sekanslar da mevcuttur.

MR görüntülerinin beyin yapısı ile detaylarını en iyi şekilde yansıtmaları ve T2 ağırlıklı sekansın da beyindeki patolojilerin saptanması açısından daha uygun olmasından dolayı çalışmamızı T2 ağırlıklı MR görüntüleri üzerinde yaptık.

## **1.2. Beynin Beyaz Cevher Bölgesindeki Yüksek Yoğunluklar**

Beyindeki beyaz cevher bölgesindeki değişikliklerin değerlendirilip, bunun eldeki delillere bakılarak bilişsel bozukluk ve bir ölçüde vasküler bir hastalık ile ilişkili olduğu tespitinde bulunulmuş. Bu durumu Binswanger hastalığından ayırmak için yeni bir terim arayışına gidilerek Yunan etimolojisi ve Hipokrat kullanımı temelinde "löko-araiosis" (Lökoaraiozis) terimi önerilmiş [14].

Önceleri, WMH MR görüntülemeye yaşlanma süreciyle ilişkili, tesadüfi ve zararsız bulgular olarak kabul edilmiştir. Bununla birlikte, küçük damar hastalığının radyolojik bir belirtisi olduğu anlaşıldığından beri, WMH çok sayıda çalışmanın konusu haline gelmiştir.

Ölüm sonrası yapılan çeşitli histolojik çalışmalar, WMH için patolojik substratlar olarak aksonal kayıp, miyelin yoğunluğunun azalması, ependimin bozulması ve sıvı birikimini ortaya koymuştur. Bununla birlikte, bu bulguyu doğrulayabilecek canlılar üzerinde yapılmış çalışma çok azdır [4].

Beynin beyaz cevher bölgesinin MR görüntülerindeki yüksek yoğunluklu alanların altında yatan patolojiyi anlamaya yönelik yapılan bir çalışmada 50-80 yaş

aralığındaki 70 denekle çalışılmış. Sonuçta kan-beyin bariyerinin olası bir şekilde parçalanması ve iltihaplanma nedeniyle hem ödem oluşumu hem de miyelin kaybının beyaz maddeyi WMH'ye dönüştüren başlıca patolojik substratlar olduğu yorumunu destekleyen sonuçlar elde edilmiş [4].

Beyaz cevherde görülen bu lezyonların altında yatan patoloji, serebral küçük damar hastalığının neden olduğu kronik iskeminin yani beynin ilgili bölgelerine kanın akışının bozulmasının bir sonucu olarak demiyelinizasyon yani sinir hücresinin elektriksel uyarıyı taşıyan uzun ve silindirik biçimindeki akson adlı parçasının çevresini saran ve onu koruyan miyelin tabakasının zarar görmesi ve aksonal kayıptır. Beyaz cevherdeki yüksek yoğunluklar ile bilişsel bozukluk ve bunama arasındaki ilişki üzerine yapılan bir araştırmada Amiloid birikiminin neden olduğu düşünülen Alzaymır hastalığında, hastalığın seyrini etkileme açısından küçük damar hastalığının Amiloidin kendisinden daha önemli olabileceği belirtilmiştir [5].

WMH'lerin bilişsel gerilemeye yol açtığına ve demansa neden olduğuna dair açık kanıtlar vardır. Topluluklar üzerinde çalışmalara göre, beyaz cevher lezyonlarının gelişimi için temel risk faktörleri ileri yaş, arteriyel hipertansiyon ve kardiyovasküler hastalıktır [5].

Serebral Küçük Damar Hastalığının gelişimi ve bilişsel sonuçlar arasında ilişkiyi anlamaya dönük bir çalışmada [6] 60-90 yaş arasındaki 668 hastanın 3 yıllık gözlemi yapılmış. Başlangıçtaki lezyon hacmi, ileri yaş, yüksek tansiyon ve sigara kullanımı birbirinden bağımsız olarak beyaz cevher lezyonlarının ilerlemesi ile ilişkili bulunmuş fakat yüksek tansiyonun bu konuda bir etkisi gözlemlenmemiş. Kadınlarda lezyon hacminde erkeklere göre daha belirgin bir ilerleme görülmüş. Lezyonun

ilerleyişi ile genel bilişsel gerileme ve bilgi işlem hızındaki düşüş arasında ilişki olduğu tespit edilmiş [6, 7].

WMH'lerin toplam hacmi ve yeri, bu lezyonları klinik açıdan anlamlandırmak için belirleyici olup, WMH'lerin şiddetini ve ilerlemesini değerlendirmek için görsel ve otomatik derecelendirme ölçekleri geliştirilmiştir. Şu ana kadar WMH varlığını ve şiddetini ölçmek için bir altın standart oluşmamış olsa da Fazekas ve Scheltens tarafından sunulmuş ve yaygın olarak kullanılan görsel derecelendirme ölçekleri yanında tam veya yarı otomatik yöntemler de vardır [5].

Beyaz cevher bölgesindeki lezyon aktivitesi ile MS hastalığı üzerine yapılan bir çalışmada lezyon hacmindeki artışın yeni lezyon oluşumundan ziyade mevcut lezyonlar içerisindeki kronik aktiviteden kaynaklandığı gözlemlenmiştir [8].

MS hastalığının MR görüntüleri ile değerlendirildiği bir çalışmada, MS ile ilişkili lezyonların en çok T2 ağırlıklı sekanslarda tanımlanabildiği, morfoloji, yerleşim yerleri ve lezyon sayılarının bu sekansla değerlendirilebildiği ifade edilmiştir.

MS lezyonlarının T2 ağırlıklı sekanslarda diğer birçok beyaz cevher patolojilerinde olduğu gibi yüksek yoğunluklu (hiperintens) görüldüğü belirtilmiş olup bunun yanında T2 ağırlıklı sekansların lezyonun yaşı ve lezyonda oluşan histopatolojik değişiklikleri gösteremediğine değinilmiştir [9].

Hipertansiyon ve şeker hastalığının beyindeki küçük damar hastalıkları ile ilgili ana faktörler olduğu tespitinde bulunan Vasküler Bilişsel Bozuklukta beyaz cevherde oluşan bozulmaya odaklanan bir çalışmada beyaz cevherde, kan-beyin bariyerine hasar verilmesi ile serum bileşenlerinin sızıntısı olduğu varsayılmıştır. Fakat bu hasara yol açan kandaki substratlar henüz tanımlanmamıştır [10].

Kan-beyin bariyerinin bozulması ile laküner inme, Lökoraiozis (beyaz cevher hiperintensiteleri) ve demans arasındaki ilişki konusunda yapılan bir araştırmada, kana ejekte edilen MR kontrast maddesinin demans ve beyaz cevher hiperintensiteleri olan hastalarda sızıntı durumları değerlendirilmiş ve bu ilişkiyi destekleyen sonuçlar görülmüş. Hipertansiyon ve diyabetin bu kaçak konusunda etkili olduğu ve beynin dışında başka organlarda da mikroanjiyopatiye neden olduğu değerlendirildi [11].

MR görüntülemesi yapılan, inme ve geçici iskemik atak öyküsü bulunmayan 65 yaş üzeri 3301 katılımcı ile yapılan bir çalışmada, beyaz cevherdeki buluntular ve bu konudaki risk faktörlerini belirlemek amaçlanmıştır. Sonuçta beyaz cevherdeki bulgular ile yaş, sessiz inme, hipertansiyon, FEV1 ve gelir anlamlı derecede ilişkili bulunmuş [12].

### **1.3. Beyin MR Görüntülerinde Derin Öğrenme Çalışmaları**

Beyin MR görüntüleri üzerinde derin öğrenme ile yapılan çalışmalar çoğunlukla beyindeki bölgelerin bölütlenmesi ile ilgilidir.

Beyin bölgeleri yanında WMH'leri de bölütleyen bir çalışmada MRBrainS13 yarışmasından bir veri seti kullanılmış. Sonuç olarak evrişimli bir sinir ağı (convolutional neural network) temelli bölütleme yöntemi yaşlı hastaların değişik derecelerdeki beyin anormalliği içeren ve motion artefacts'li MR görüntülerindeki beyin dokularını ve WMH leri doğrulukla bölütleyebilmiş. WMH'nin bölütlenmesi, WMH'nin daha yüksek heterojenliği nedeniyle, beyin dokularının bölütlenmesinden daha düşük bir performansa sahipti. Ayrıca, beyin dokusu bölütlenmesi ile karşılaştırıldığında, WMH bölütlenmesi, motion artefacts ve beyin enfarktüsü gibi diğer beyin anormalliklerinin varlığına karşı daha hassastı [1].

Demansın nedenlerinden olan Alzaymır hastalığının teşhisi için derin öğrenme modeli öneren bir çalışmada ADNI (The Alzheimer's Disease Neuroimaging Initiative) veritabanından alınan Alzaymır ve normal kontrol hastalarına ait MR görüntüleri üç boyutlu evrişimli sinir ağları için eğitim ve test verisi olarak kullanılmış. Derin öğrenme modeli eğitilirken ve test edilirken 246 hastanın 1 yıl boyunca ilk ziyaret, 6. ay ziyareti ve 12. ay ziyaretlerinde çekilmiş MR 1.5Tesla görüntüleri kullanılmış. Çalışmada önerilen yöntem %90.6 doğruluk ile karşılaştırıldığı 8 yöntem arasından 5. olmuş [2].

Beyindeki tümörlerin tespitine yönelik bir çalışmada Rembredant, Harvard ve Benchmark veri setlerinden 252 adet MR görüntü üzerinde 4 farklı Bölgesel Tabanlı Evrişimsel Sinir Ağı (BESA) denenmiş ve sonuçlar kendi arasında karşılaştırılmış. Yöntemlerden biri tümör tespiti konusunda %99,82 doğruluk oranına ulaşabilmiş. [3]

## II. DERİN ÖĞRENME

Derin öğrenme, insan zekasının çözebildiği karmaşık problemleri çözmek için algoritma, veri ve donanımsal hesaplama gücü kullanan sistemlerin geliştirilmesi için disiplinler arası bir çalışma alanıdır şeklinde tanımlanmaktadır. Hiyerarşik açıdan derin öğrenme, makine öğrenmenin bir alt dalı olup makine öğrenme de yapay zekanın bir alt dalı olarak sıralanabilir. Derin öğrenmeyi makine öğrenmeden ayıran en temel özellik öznitelik çıkarma konusudur. Makine öğrenmede öznitelik çıkarımı için bir uzmana ihtiyaç duyulur. Çıkarılan bu öznitelikler ile model beslenir. Fakat derin öğrenmede bu işlem giriş katmanında modele verilen çok fazla sayıdaki verinin yapay sinir ağının gizli katmanları boyunca işlenmesi ile otomatik olarak gerçekleşir. Gizli katmanlarda elde edilen öznitelikler çıkış katmanına verilerek sınıflandırma işlemi yapılır. Yapay sinir ağının eğitimi için kullanılan veri ne kadar büyük ve çeşitli ise başarı o kadar yüksek olmaktadır.

### 2.1. Derin Öğrenmenin Tarihçesi

Bir sinir ağının matematik modeli ilk defa 1943 yılında bir hekim olan Warren McCulloch ve matematikçi Walter Pitts tarafından ortaya konulmuştur. Bu model McCulloch–Pitts nöronu olarak isimlendirilmiştir [19]. Amerikalı bir uzay mühendisi olan Henry J. Kelley, tarafından 1960 yılında yayınlanan "Optimal Uçuş Yollarının Gradyan Teorisi" başlıklı makale yapay sinir ağlarında kullanılan en önemli algoritmalarından biri olan geri yayılım algoritmasının temellerini oluşturmaktadır [20]. Ivakhnenko and Lapa denetimli, derin, ileri beslemeli ve çok katmanlı algılayıcıları için ilk genel ve çalışan öğrenme algoritmasını 1965 yılında yayınladılar [21]. Japon bilgisayar bilimcisi Kunihiko Fukushima 1980 yılında hiyerarşik, çok katmanlı bir

yapay sinir ağı olan Neocognitron'u önermiştir. Bunu Japon el yazısı karakterleri ve diğer dokuları tanımak için kullanmıştır [22]. 1986 yılında Derin Öğrenmenin babası kabul edilen Hinton ile Rumelhart ve Williams 1986 yılında yaptıkları "Geri yayılım hatalarıyla öğrenme temsilleri" isimli çalışmada yeni bir öğrenme prosedürü tanımlamışlardır. Bu geri yayılım prosedürü hedeflenen çıkış vektörü ile ağıın mevcut çıkış vektörü arasındaki farkı minimize etmek için ağıdaki bağlantıların ağırlıklarının ayarlayacak şekilde sürekli tekrar eder. Ağırlıkların ayarlanması ile girişin ve çıkışın bir parçası olmayan dahili gizli üniteler görev alanının önemli özneliliklerini temsil etmeye başlar [23]. Geri yayılım algoritmaları daha önce keşfedilmiş olsa da 1989 yılında Yann LeCunn ve arkadaşları el yazısı posta kodlarını tanımak için geri yayılımı bir yapay sinir ağı üzerinde başarıyla kullandılar [24]. Bu uygulama günümüzdeki uygulamalara en yakın çalışmaydı fakat o zamanki bilgisayarların hesaplama gücü çok düşük olduğundan efektif bir kullanım sağlamamıştı. 1997 yılına gelindiğinde Jürgen Schmidhuber ve Sepp Hochreiter bir Yinelemeli Sinir Ağı mimarisi olan Uzun Kısa Süreli Bellek (LSTM) mimarisini ortaya koydu [25]. Bununla standart ileri beslemeli yapay sinir ağlarından farklı olarak geri bildirim bağlantıları da yapmaktadır. Bu ağlar ile yalnızca resim gibi anlık, durağan verileri değil, zaman serisi şeklinde akan konuşma veya video gibi veriler de işlenebilmektedir. 1998 yılında Yann LeCun doküman tanıma için gradyan temelli öğrenme çalışmasında LeNet ismini verdiği Evrişimsel Sinir Ağı (ESA) mimarisini kullanarak 0-9 arasındaki el yazısı rakamları başarıyla sınıflandırabilmişti [26]. YSA'ların başarısındaki en büyük darboğazlardan biri olan eğitim verisi ihtiyacı için 2009 yılında Prof. Li Fei-Fei önderliğindeki bir ekip tüm dünyadan çok sayıda katılımcının desteğiyle etiketlenmiş görüntülerden ImageNet isminde bir veri seti oluşturdu. Bu veri setinin en fazla kullanılan bir alt seti olan

ILSVRC (ImageNet Large Scale Visual Recognition Challenge) 1000 nesne sınıfından yaklaşık 1,5 milyon görüntü içermektedir. Bu veri setinin araştırmacılara açılmasıyla yapay sinir ağları daha popüler bir hale geldi. YSA'larının yakın zamanda tekrar gündeme gelmesi 2012 yılında Alex Krizhevsky'in önerdiği ve Grafik İşlem Birimi (GPU) üzerinde çalışan AlexNet isimli modelin ImageNet ILSVRC yarışmasında elde ettiği yüksek başarımla olmuştur. Çekişmeli Üretici Ağlar 2014 yılında Ian Goodfellow ve arkadaşları tarafından NIPS konferansında tanıtılmıştır. Önerilen bu ağda üretici ve ayırıcı olarak tanımlanan iki ağın çekişmesi ile öğrenme gerçekleşmektedir. Üretici bu çekişmede kendini daha da iyileştirerek referans veriye yaklaşmaktadır. [27] Bu ağlar bugüne kadar yapılan derin öğrenme çalışmalarının ilerisine geçerek stil transferi, görüntü üretme, görüntü iyileştirme ve yüz yaşlandırma gibi daha sofistike alanlarda oldukça başarılı sonuçlar vermiştir.

## 2.2. Evrişimli Sinir Ağları

Izgara benzeri topolojiye sahip verileri işlemek için kullanılan özel bir tür sinir ağıdır. Evrişimli adı, ağın evrişim adı verilen özel bir matematiksel işlem kullandığını gösterir [30].

Derin öğrenmede her problem için farklı bir ağ mimarisi kullanılır. Görüntüler üzerindeki sınıflandırma işlemleri için çoğunlukla ESA kullanılırken, sesten yazıya, yazıdan sese çevirme, otomatik tercüme, anlık değişen finans verileri üzerindeki analizler gibi zaman serisi tipindeki verilerde Yinelemeli Sinir Ağları tercih edilir. Üretici Ağlar ise metin, ses, görüntü üretme ve artistik stil transferi gibi ihtiyaçlarda tercih edilir. Çalışma konumuz MR görüntüleri üzerine olduğu için çalışmamızda ESA kullanmayı tercih ettik.


### 2.2.1. Evrişimli Sinir Ağı Katmanları

Bir ESA giriş katmanı, gizli katmanlar ve çıkış katmanı olarak üç ana yapıdan oluşan bir modeldir. Bu katmanlar birbirlerine bir zincir yapısıyla bağlıdır. Bu zincir yapının uzunluğu aynı zamanda modelin derinliğidir. Derin öğrenme adı da bu terminolojiden ortaya çıkmıştır [30].

Giriş katmanında probleme ve modele uygun olarak hazırlanmış çok miktarda görüntü matrisler olarak modele verilir.

Gizli katmanlar bazı özel işlevleri olan alt katmanlardır. Bu katmanlarda giriş verisinden öncelikle alt seviye öznitelikler olan kenar, köşe ve ışık gibi öznitelikler ilerleyen katmanlarda ise daha üst seviyelerdeki, daha karmaşık öznitelikler sentezlenir. Bu katmandan çıkan veriler çıkış katmanına iletilir.

Çıkış katmanı, tam bağlantı katmanı olarak da ifade edilebilir. Burada matris şeklindeki veriler vektörlere dönüştürülür ve softmax gibi bir olasılık fonksiyonu kullanılarak çıkış verisi sınıflandırılır.



Şekil II.1. ESA katmanlarının temsili görünümü.



### 2.2.2. Gizli Katmanlar

Bir yapay sinir ağında özniteliklerin çıkarıldığı en karmaşık bölge gizli katmanlardır. Bir YSA'da çok sayıda nöron içeren gizli katmanların kullanılması, YSA'nın modelleme gücünü önemli ölçüde artırır ve birbirine yakın birçok optimal konfigürasyon oluşturur [31]. ESA'daki gizli katmanlar evrişim katmanları ve ortaklama katmanlarından oluşur. Evrişim katmanlarında giriş matrisleri üzerinde birtakım filtre matrisler gezdirilerek görüntüdeki öznitelikler sentezlenir. Elde edilen yeni matrisler bir sonraki katmana giriş verisi olarak verilir. Kullanılan filtrelerin boyutları, içerikleri ve kaydırma şekli gibi parametreler tamamen problem, dolayısıyla ağın mimarisine göre belirlenir. Kullanılan filter sayısı ne kadar fazla ise hesaplanan parameter sayısı da o kadar fazla olmaktadır. Bir sonraki katman yeni bir evrişim katmanı olabileceği gibi bir ortaklama katmanı da olabilir. Ortaklama katmanında ise yine birtakım filtre matrisler kullanılır. Ancak bunlar öznitelik çıkarmak için değil giriş matrisinin boyutunu küçültmek için kullanılır. En çok kullanılan ortaklama yöntemleri maksimum ortaklama ve ortalama ortaklama yöntemleridir.

### 2.2.3. İleri ve Geri Yayılım

Bir yapay sinir ağında veri katmanlar arasında ilerlerken birtakım hesaplamalar yapılır. Her giriş verisi kendisi ile ilişkili bir ağırlık değeriyle çarpılır. Bu çarpımların sonuçları toplanır ve ardından bu toplama bir bias değeri eklenir. Elde edilen bu toplam doğrusal olmayan bir aktivasyon fonksiyonuna tabi tutulur. Ardından bu fonksiyonun çıktısı bir sonraki katmana giriş verisi olarak verilir. Çıkış katmanına gelindiğinde katmanların çıktı sayısı tahmin edilecek sınıf sayısına kadar indirgenmiş olur. Bu aşamada bir softmax fonksiyonu kullanılarak toplamı 1 olacak şekilde her bir sınıf için bir olasılık değeri hesaplanır. Tahmin sonucu, olasılığı en yüksek sınıf olur. YSA'da

İleri yayılım bu adımlarla gerçekleşir. Ağırlık değeri, YSA'daki o nöronun ağırlık çıkışında elde edilen sonuç üzerinde ne kadar etkili olduğunu belirler. İleri yayılımın bir YSA hücresi üzerinde temsili gösterimi Şekil II.2.a'da görülmektedir.



Şekil II.2. Bir yapay sinir ağı hücresinin (a) [36] ve biyolojik sinir hücresinin (b) [35] temsili gösterimleri.

İleri yayılım sonucunda tahmin edilen sınıf hatalı ise, hatayı minimize etmek için çıkış katmanından geriye doğru giriş katmanına kadar bir geri yayılım algoritması uygulanır. Geri yayılım sırasında nöronların ağırlık değerleri güncellenerek hata minimize edilmeye çalışılır. Çıkış sonucunu değiştirmek için ağırlıkları değiştirmek söz konusu olduğundan geri yayılım sırasında zincir kuralına göre kısmi türev alma işlemleri uygulanır. Her geri yayılım sonrasında ağırlıklar güncellenmiş olur.

$j$ 'inci çıktı hücresi için  $n$ 'inci eğitim verisi sonrası,  $d_j(n)$  beklenen değer olmak üzere hata, denklem (2.1)'deki gibi tanımlanır.

$$e_j(n) = d_j(n) - y_j(n) \quad (2.1)$$

Çıktı katmanındaki toplam hata, denklem (2.2)'deki gibi ifade edilir.

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.2)$$

Çıktı katmanındaki tüm nöronlar  $C$  kümesine dahildir. Burada  $E(n)$  en düşük değere getirilmeye çalışılır. Çıktı katman hücresine gelen girdilerin toplamı denklem (2.3) ile ifade edilmiştir.

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) x_i(n) \quad (2.3)$$

$X=(x_1, \dots, x_n)$ ,  $j$ 'inci nörona uygulanan  $m$  girdi değerini göstermektedir.  $w_j$ ,  $x_i$  girdisinin ağırlığını ve  $f$  aktivasyon fonksiyonunu göstermektedir.  $w_{j0}$  sapma elemanını gösterir ve böylece  $x_0=+1$  olur.

Ağın çıktı hücrelerinin ürettiği sonuç denklem (2.4) ile hesaplanır.

$$y_j(n) = f(v_j(n)) \quad (2.4)$$

Ağın gradyanı hata fonksiyonunun ağırlıklara göre türevi alınarak bulunabilir. Zincir kuralına göre gradyan, denklem (2.5)'daki gibi ifade edilebilir.

$$\frac{\partial E(n)}{\partial W_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.5)$$

Tek tek türevler alındığında,

$$\frac{\partial E(n)}{\partial W_{ji}(n)} = -e_j(n)f(v_j(n))x_i(n) \quad (2.6)$$

Ağırlık düzeltme miktarı  $\Delta W_{ji}(n)$  delta kuralına göre uygulanır.

$$\Delta W_{ji}(n) = -\eta \frac{\partial E(n)}{\partial W_{ji}(n)} \quad (2.7)$$

$\eta$  öğrenme oranıdır. – simgesi ağırlık uzayındaki dik inişi temsil eder. Böylece geriye yayılım algoritması için ağırlık düzeltme miktarı denklem (2.8)'daki gibi ifade edilir.

$$\Delta W_{ji}(n) = \eta \delta_j(n) x_i(n) \quad (2.8)$$

Yerel gradyan  $\delta_j(n)$  ise denklem (2.9)'daki gibi tanımlanır.

$$\delta_j(n) = e_i(n) f'(v_i(n)) \quad (2.9)$$

Gizli katmandaki herhangi bir j nöronu için, çıkış katmanındaki nöronlarda olduğu gibi istenen çıktı değeri belirtilmemiştir. Bu nedende gizli bir j nöronunun hata değeri, o nöronun bağlı olduğu tüm nöronların hata değerinden geriye dönük olarak etkilenecektir. Gizli katmandaki herhangi bir j nöronu için, yerel gradyan  $\delta_j(n)$  denklem (2.10)'deki gibi tanımlanır.

$$\delta_j(n) = f'(v_i(n)) \sum_{j=0}^l \delta_j(n) w_{ji}(n) \quad (2.10)$$

Rumelhart 1986 yılında, geriye yayılım algoritmasındaki ağırlık güncelleme denklemine,  $\alpha$  momentum terimi ekleyerek, ağırlık yerel minimuma takılma olasılığını azaltmıştır.  $\alpha$  terimi eklendikten sonra ağırlık güncelleme denklemi (2.11) ve (2.12)'teki hali alır [33].

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (2.11)$$

$$\Delta w_{ji}(n) = \eta \delta_j(n) x_i(n) + \alpha \Delta w_{ji}(n) \quad (2.12)$$

#### 2.2.4. Transfer Öğrenme

Sıfırdan bir görüntü sınıflandırma eğitimi çok uzun ve zor bir süreç olup, büyük veri setleri kullanıldığından tamamlanması yüksek performanslı donanımlar üzerinde bile günlerce sürebilmektedir.


Genellikle çok katmanlı modellerde eğitim süresini azaltmak ve performansı artırmak için kullanılır. Bir yapay sinir ağının ilk katmanlarında kenar ve köşe bilgisi gibi basit öznitelikler sentezlenirken ilerleyen katmanlarda ise daha üst seviye öznitelikler sentezlenmektedir. Bu basit öznitelikler aynı alandaki farklı problemler için genellikle ortaktır. Bu nedenle daha önce farklı verilerle ve farklı bir modelin eğitimi sonucunda oluşmuş ağırlıklar kısmen başka bir modelin girişinde kullanılabilir. ImageNet üzerinde önceden eğitilmiş bir modeli kullanmak kenarlar gibi düşük seviyeli öznitelikleri öğrenmek için faydalı olacaktır [32]. Çalışmamızda kullandığımız donanım kapasitesinin düşük olması ve veri setimizin yeterince büyük olmamasından dolayı ImageNet veri seti ile eğitilmiş VGG16 isimli model ile transfer öğrenme yaptık.

#### 2.2.5. VGG16 Modeli

Bir ESA modeli olan VGG16 Oxford Üniversitesi Mühendislik Bilimi Departmanı Görsel Geometri Grubundan (Visual Geometry Group) Karen Simonyan ve Andrew Zisserman tarafından 2015 yılında bir evrişimli ağın derinliğinin başarımına etkisi üzerine yaptıkları çalışma ile sunulmuştur [28].

Model adını Visual Geometry Group çalışma grubunun kısaltması ve 13'ü evrişim ve 3'ü tam bağlantı olan toplam 16 adet katman sayısından almaktadır.

3x3'lük çok küçük evrişim filtreleri kullanılan bu model ImageNet 2014 yarışmasında yerleştirme parkurunda birincilik ve sınıflandırma parkurunda ise ikincilik elde etmiştir [28].



Şekil II.3. VGG16 evrişimli sinir ağı modelinin mimarisi.

### III. MS HASTALARI MR GÖRÜNTÜ VERİ SETİ

Bu çalışmada Lesjak ve arkadaşlarının yaptığı bir çalışmanın çıktısı olan ve Ljubljana Üniversitesi'nin (Slovenya) web sitesi üzerinden araştırmacıların erişimine açtığı bir veri seti kullanılmıştır [34] [18].

#### 3.1. Veri Setinin İçeriği

Bu veri seti 20 farklı MS hastasının iki farklı zamanda çekilmiş MR görüntüleri ve beraberinde beyaz cevherdeki lezyon değişimlerinin bölütlenip kesin referans (ground truth) verisi olarak verildiği bir içeriğe sahiptir.

Görüntüler her hasta için klasörler içerisinde gruplanmıştır. Her klasörde iki farklı zamanda çekilmiş, birlikte kaydedilmiş ve N4 düzeltilmiş, T1 ağırlıklı, T2 ağırlıklı ve FLAIR görüntüler, beyin maskeleri, beyaz cevher lezyon değişim maskeleri, RAW görüntüler, intrastudy dönüşüm parametreleri ve RAW'dan dönüşüm parametreleri bulunmaktadır [18].

Dört ayrı sıkıştırılmış dosyaya bölünmüş yirmi farklı hastanın .nii (NIfTI Data Format by Neuroimaging Informatics Technology Initiative [7]) dosya formatında MR görüntüleri vardır. Görüntüler patient01-05.zip, patient06-10.zip, patient11-15.zip, patient16-20.zip isminde dört adet sıkıştırılmış dosyadan oluşmaktadır. Sıkıştırılmış dosyalar içerisinde her hasta için Şekil III.1.'de gösterilen dosyalar vardır.

| Ad                                      | Değiştirme tarihi | Tür           | Boyut     |
|-----------------------------------------|-------------------|---------------|-----------|
| raw                                     | 13.11.2020 22:33  | Dosya klasörü |           |
| patient11_brainmask.nii.gz              | 16.01.2017 00:05  | WinRAR arşivi | 34 KB     |
| patient11_gt.nii.gz                     | 16.01.2017 00:05  | WinRAR arşivi | 6 KB      |
| patient11_study1_FLAIR_to_common_spa... | 15.01.2017 23:54  | Metin Belgesi | 1 KB      |
| patient11_study1_FLAIRreg.nii.gz        | 16.01.2017 00:05  | WinRAR arşivi | 5.323 KB  |
| patient11_study1_T1Wreg.nii.gz          | 16.01.2017 00:05  | WinRAR arşivi | 13.554 KB |
| patient11_study1_T2Wreg.nii.gz          | 16.01.2017 00:05  | WinRAR arşivi | 13.567 KB |
| patient11_study2_FLAIR_to_common_spa... | 15.01.2017 23:54  | Metin Belgesi | 1 KB      |
| patient11_study2_FLAIRreg.nii.gz        | 16.01.2017 00:05  | WinRAR arşivi | 5.455 KB  |
| patient11_study2_T1Wreg.nii.gz          | 16.01.2017 00:05  | WinRAR arşivi | 13.282 KB |
| patient11_study2_T2Wreg.nii.gz          | 16.01.2017 00:05  | WinRAR arşivi | 13.710 KB |

Şekil III.1. Patient11 isimli hasta için veri setindeki dosya içeriği

Dosya isimlerindeki study1 ilk çekimi (baseline), study2 ikinci çekimi (follow-up) ifade ediyor. T1W, T2W ve FLAIR ise MR görüntülerinin hangi sekanslarda çekildiğini ifade ediyor. Brainmask ile beyin görüntüsünün arka fondan ayrılmış olacak şekilde siyah zeminde beyaz beyin görüntüsü şeklinde veriliyor. GT ise study1 ile study2 arasındaki WMH hacmindeki değişimi siyah zeminde beyaz pikseller olarak gösteriyor. Biz çalışmamızda Kesin Referans (KR) verisi olarak bu GT piksellerin study1 zamanındaki, T2 ağırlıklı sekanstaki çekimlerine karşılık gelen pikselleri kullanıyoruz. Çalışmamızdaki hedefimiz yalnızca study1 zamandaki görüntüleri ve KR pikselleri kullanarak bir YSA'yı eğitmek ve ileride nerede WMH oluşacağını tahmin etmek.


Örnek olarak, patient10 isimli hasta için .nii formatındaki veriyi Python programlama dili ortamında Numpy kütüphanesi kullanılarak bir diziye aktarıp Matplotlib kütüphanesi ile ekranda görüntülediğimizde aşağıdaki ebatlardaki ve düzlemlerdeki görsellerle karşılaşırız. .nii formatındaki veriler 64 bit kayan

noktalı sayı formatındayken ekrandan 8 bit gri tonlu görseller elde edilmektedir. .nii formatındaki verileri işlerken buna benzer dönüşümlerin yapılması gerekmektedir.


287 x 296 boyutlarında 56 adet Axial (Üstten Alta) düzlemde görüntü.

287 x 56 boyutlarında 296 adet Coronal (Önden Arkaya) düzlemde görüntü.


296 x 56 boyutlarında 287 adet Sagittal (Soldan Sağa) düzlemde görüntü.



Şekil III.2. Patient10 isimli hastanın axial düzlemdeki örnek MR görüntüleri.



Şekil III.3. Patient10 isimli hastanın coronal düzlemdeki örnek MR görüntüleri.



Şekil III.4. Patient10 isimli hastanın sagittal düzlemdeki örnek MR görüntüleri.

Daha yüksek görüntü kalitesinde olmasından ve daha fazla detay içermesinden dolayı çalışmamızda axial düzlemdeki görüntüleri kullandık. Veri setimizde axial düzlemde toplam 1.140 adet kesit (slice) bulunmaktadır.

Tablo III.1. Veri setindeki tüm hastaların MR görüntülerinin sayısı.

| <b>Hasta Numarası</b> | <b>Sagittal Görüntü Sayısı</b> | <b>Coronal Görüntü Sayısı</b> | <b>Axial Görüntü Sayısı</b> |
|-----------------------|--------------------------------|-------------------------------|-----------------------------|
| patient10             | 287                            | 296                           | 56                          |
| patient11             | 261                            | 260                           | 48                          |
| patient12             | 334                            | 352                           | 60                          |
| patient13             | 260                            | 274                           | 55                          |
| patient14             | 284                            | 278                           | 48                          |
| patient15             | 283                            | 285                           | 58                          |
| patient16             | 275                            | 293                           | 60                          |
| patient17             | 260                            | 264                           | 51                          |
| patient18             | 268                            | 260                           | 50                          |
| patient19             | 328                            | 336                           | 53                          |
| patient1              | 325                            | 334                           | 53                          |
| patient20             | 280                            | 304                           | 65                          |
| patient2              | 262                            | 274                           | 53                          |
| patient3              | 333                            | 361                           | 66                          |
| patient4              | 272                            | 268                           | 50                          |
| patient5              | 265                            | 267                           | 47                          |
| patient6              | 267                            | 312                           | 81                          |
| patient7              | 269                            | 296                           | 64                          |
| patient8              | 282                            | 292                           | 67                          |
| patient9              | 314                            | 429                           | 55                          |

## IV. UZMAN SİSTEM TASARIMI

Önerilen uzman sistemde veri işleme ve YSA'nın eğitimi öncesi üzerinde çalışılmak üzere Axial düzlemdeki T2 ağırlıklı MR görüntü sekansları seçildi. Bu görüntü sekanslarına ait veriler belirlenen formata dönüştürülerek diske saklanır. Diske kaydedilen veriler ön işlemlerden geçirilir. Ön işleminden geçirilen MR kesitlerinden KR ve KR-Değil olarak etiketlenmiş pikselleri merkezine alan görüntü yamaları toplanır. Bu görüntü yamaları eğitim, doğrulama ve test için belirli oranlarda bölünerek YSA'nın eğitiminde kullanılır. YSA'nın eğitiminde en iyi sonucu elde edebilmek için veri çoğaltma yöntemleri uygulanır ve hiper parametrelerden de yararlanarak ağırlık eğitimi sonrası bir model dosyası elde edilir. Tez çalışmasında geliştirilen web tabanlı test uygulaması ağırlık çıktısı olarak elde edilen bu model dosyasını, harici MR görüntüleri üzerinde piksel tabanlı sınıflandırma yaparak başarımlar hesaplanmasında ve renklendirilmiş görüntü çıktısını üretmede kullanılır.

### 4.1. Kullanılan Araçlar

Çalışmada kullanılan donanım ve yazılımlar aşağıdaki gibidir;

Donanımlar:

Merkezi İşlem Birimi (CPU): 4 çekirdekli Intel Core i7 870 @2.93GHz

Grafik İşlem Birimi (GPU): 2GB NVIDIA GeForce GTX 760

Bellek (Memory): 20GB

Sabit Disk (HDD): 500GB 3.5" 7200RPM 32MB SATA

Yazılımlar:

İşletim Sistemi (OS): Ubuntu 16.04 LTS

Makine Öğrenme Platformu: TensorFlow

Derin Öğrenme API: Keras

Programlama Dili: Python

Programlama Ortamı 1: Jupyter Notebook (IPython Notebooks)

Programlama Ortamı 2: PyCharm

Uzaman Sistem İçin Web Çatısı: Flask

## 4.2. Veri Setinin Yapay Sinir Ağı İçin Hazırlanması

Veri setinde bulunan tüm MR görüntüleri içerisinde T2 ağırlıklı sekans ile çekilmiş görüntülerin Axial düzlemdeki kesitleri kullanılmıştır. Bunun nedeni T2 ağırlıklı sekansın beyindeki lezyon benzeri patolojilerin saptanması açısından daha uygun olmasıdır.

Çalışmamızın başlangıcındaki denemelerde 20 hastanın tamamının görüntülerini kullanarak YSA'nın eğitim, sınav ve testlerini gerçekleştirdik. Daha sonraki denemelerde belirlenen 2 hastanın tüm görüntüleri veri setinden ayrılıp yalnızca 18 hastanın görüntüleri kullanıldı. Kalan 2 hastanın görüntüleri ise gerçekleştirilen web tabanlı test uygulaması ile tahminlemede kullanılmıştır.

### 4.2.1. Verileri Saklama Biçimi

Ağın eğitimi için verilecek olan görüntüleri ilişkili olduğu hasta ve kesit bilgisi ile birlikte saklamak için üç ayrı .npz formatındaki (Sıkıştırılmış Numpy Dizileri) dosyada saklıyoruz. Aynı uzunluktaki bu üç ayrı dosyadaki veriler arası ilişki dosyalar içerisindeki verilerin indis sırasıyla sağlanıyor. Tablo IV.1'de bu ilişki temsili olarak gösterilmiştir.

Tablo IV.1. Görüntü, hasta ve kesit bilgisini ilişkili bir şekilde saklamak için kullanılan .npz formatındaki dosya içeriklerinin temsili gösterimi.

| <b>Image.npz</b> | <b>Patient.npz</b> | <b>Slice.npz</b> |
|------------------|--------------------|------------------|
| Image 1          | Patient no 1       | Slice no 1       |
| Image 2          | Patient no 1       | Slice no 2       |
| Image 3          | Patient no 2       | Slice no 1       |
| Image 4          | Patient no 2       | Slice no 2       |
| Image 5          | Patient no 2       | Slice no 3       |
| Image 6          | Patient no 3       | Slice no 1       |


#### 4.2.2. Beyaz Cevher Lezyon Değişim Maskelerinin Saklanması

hastaadı\_gt.nii.gz isimli dosyalarda axial, coronal ve sagittal düzlemdeki görüntüler için Kesin Referans (KR) olan pikseller siyah zeminde beyaz pikseller olarak işaretlenmiş olarak verilmektedir. Bu dosyalardan axial düzlemdeki görüntüler toplanıp, ilişkili oldukları hasta ve kesit numarası ile birlikte saklanıyor. Bu veriler aynı zamanda çalışmamızda KR olarak kullanılacak. Saklanan dosyaların isimlendirmesi şöyledir:

A\_gt\_wml\_change\_mask\_axial\_img.npz

A\_gt\_wml\_change\_mask\_patientno.npz

A\_gt\_wml\_change\_mask\_sliceno.npz



Şekil IV.1. patient12 isimli hastanın axial düzlemdeki 25. kesitinde KR alanların görünümü.

#### 4.2.3. Beyaz Cevher Lezyon Değişim Maskelerindeki KR Koordinatların

##### Saklanması

Bir önceki adımda saklanan görüntülerdeki siyah zeminde beyaz işaretli piksellerin koordinat bilgileri ile ilişkili oldukları hasta ve kesit bilgileri .npz formatında dosyalarda saklanıyor. 20 hastadan patient1 ve patient20 ayrıldıktan sonra kalan 18 hasta için KR koordinat sayısı 67.972 adettir. Saklanan dosyaların isimlendirmesi şöyledir:


B\_gt\_mask\_axial\_koords\_y\_x.npz

B\_gt\_mask\_axial\_patientno.npz

B\_gt\_mask\_axial\_sliceno.npz

#### 4.2.4. Axial Düzlemdeki T2 Ağırlıklı MR Görüntülerinin Saklanması

Bu aşamada ileride YSA'nın eğitimi için kullanacağımız görüntü yamalarını üzerinden alacağımız T2 ağırlıklı axial düzlemdeki MR kesitlerini ilgili hasta ve kesit numarası bilgisi ile birlikte saklıyoruz. Saklanan dosyaların isimlendirmesi; C\_T2\_axial\_img.npz, C\_T2\_axial\_sliceno.npz, C\_T2\_axial\_patientno.npz




Şekil IV.2. patient12 isimli hastanın axial düzlemdeki 25. Kesitinin görünümü (Matplot görüntüyü ekranda gösterirken otomatik renklendirmiştir. Orjinal görüntü siyah beyazdır).

#### 4.2.5. Kesitlerdeki Beyin Alanlarının Konturlarının Hesaplanması

İlerideki aşamalarda kesitler üzerinde çalışırken vakit kaybetmemek ve ilgisiz alanların oluşturacağı karışıklıktan etkilenmemek için yalnızca beyin ile ilgili alanlar belirleniyor. Bunun için görüntüde bölütleme yapıp elde edilen alanlardan en büyüğü seçilip bu alanı çevreleyen kontur bilgisi ilgili hasta adı ve kesit numarasıyla birlikte


saklanıyor. Saklanan dosyaların isimlendirmesi; E\_axial\_contours.npz, E\_axial\_contours\_patientno.npz, E\_axial\_contours\_sliceno.npz



Şekil IV.3. patient4 isimli hastanın 43 numaralı kesiti (solda), görüntü üzerinde hesaplan kontur (ortada) ve kontur koordinatlarının görselleştirilmesi (sağda).

#### 4.2.6. Kesitlerin Normalize Edilmesi


Daha önce kaydedilmiş olan kesitler YSA'ya verilmeden önce normalize ediliyor. Normalizasyon için yalnızca kontur içerisindeki pikseller dikkate alınıyor. Normalizasyon için farklı yöntemler uygulanıyor. Uygulanan yöntemlerin detayları ve başarımları ilerideki denemeler bölümünde karşılaştırmalı olarak verilmektedir. Normalize edilen kesitler ilgili hasta adı ve kesit numarasıyla birlikte saklanıyor.



Şekil IV.4. Normalize edilmiş görüntü (solda) ve orjinal görüntü (sağda).

#### 4.2.7. Normalize Edilmiş Kesitlerden KR Koordinatları Merkezine Alan Görüntü Yamalarının Üretilmesi

Daha önce .npz formatında saklanmış olan KR koordinatları merkezine alan görüntü yamaları normalize edilmiş kesit üzerinden alınıp ilgili hasta adı ve kesit numarasıyla birlikte saklanıyor. Denemeler sırasında farklı yama boyutları da denenmiş olup büyük çoğunlukla 21x21 piksel boyutlarındaki yamalarla çalışılmıştır.




Şekil IV.5. patient19 isimli hastanın 24 numaralı kesitindeki y:213, x:176 KR koordinatı merkezine alan 21x21 piksel boyutundaki görüntü yaması.

#### 4.2.8. KR-Değil Görüntü Yamalarının Alınması

Kullandığımız YSA'nın görüntüdeki bir pikseli WMH veya Non-WMH olarak sınıflandırmasını istiyoruz. Dolayısıyla 2 adet sınıfımız var. YSA'yı eğitirken KR pikselleri merkezine alan yamalar yanında KR-Değil pikselleri merkezine alan yamalar da veriyoruz. Bunun için normalize edilmiş kesitler üzerindeki kontur sınırları içerisinde olan ve KR pikselleri merkezine alan yamalarla çakışmayan rastgele yamalar belirliyoruz.


KR ve KR-Değil yamaların birbirleri ile çakışmaması için, her axial görüntü üzerinde varsa KR pikseli merkezine alan yamalar kırmızıya boyanarak ilgili hasta adı ve kesit numarasıyla birlikte saklanıyor. Daha sonra bu veri çakışma kontrolü için

kullanılıyor. Çakışma kontrolü için kullanılan örnek veriler Şekil IV.6.'da gösterilmiştir.



Şekil IV.6. patient11 isimli hastanın 35 numaralı kesitindeki KR pikseller (sağda) ve bu pikselleri merkezine alan kırmızı boyalı yamalar (solda).

Uygun koşulları sağlayan rastgele üretilmiş koordinatları merkezine alan yamalar ilgili hasta adı ve kesit numaralarıyla birlikte .npz formatında saklanıyor.




Şekil IV.7. patient14 isimli hastanın 28 numaralı kesitindeki y:119, x:68 rastgele belirlenmiş koordinatı merkezine alan 21x21 piksel boyutundaki görüntü yaması.

#### 4.3. Yapay Sinir Ağının Eğitimi

Bu bölümde YSA'nın eğitiminde kullanmak üzere hazırlanmış olan veri setinin modele verilerek eğitim ve test sürecinin işleyişi açıklanmaktadır.


.npz formatında dosyalarda saklanan KR görüntü yamaları (Denemeler sırasında WMH olarak ifade edilmektedir) ve rastgele üretilmiş KR-Değil görüntü yamaları (Denemeler sırasında Non-WMH olarak ifade edilmektedir) numpy diziler olarak belleğe yüklenir.

Görüntü yamalarına karşılık gelen aynı sayıda etiket bilgisi belleğe yüklenir. WMH görüntüler [0, 1], Non-WMH görüntüler ise [1, 0] sınıf etiketiyle etiketlenir.



Şekil IV.8. Sınıf etiketleri ile beraber örnek görüntü yamaları.

Çalışmada kullanılan YSA olan VGG16 en az 48x48 piksel ebatlarındaki 3 kanallı görüntüler ile çalıştığından, veri setimizdeki 21x21 piksel ebatlarındaki tek kanallı görüntü yamaları önce 48x48 ebatına büyütülüyor ardından mevcut tek kanallar üst üste konularak 3 kanallı hale getiriliyor.



Şekil IV.9. Non-WMH sınıfından 48x48 ebatlarına boyutlandırılıp, 3 kanallı hale getirilmiş örnek bir görüntü yaması.

Veri setindeki görüntüler eğitim, sınama ve test amaçlı kullanılmak üzere farklı oranlarda üçe bölünüyor.

Modelin eğitiminde kullanılacak hiper parametrelerin değerleri belirleniyor.


Transfer öğrenme için kullanılacak modelin son 4 katmanı hariç diğer giriş katmanları olduğu gibi kullanılmak üzere donduruluyor.

```
<keras.engine.topology.InputLayer object at 0x7f5385fc85f8> False
<keras.layers.convolutional.Conv2D object at 0x7f5385fc88d0> False
<keras.layers.convolutional.Conv2D object at 0x7f5385fc8860> False
<keras.layers.pooling.MaxPooling2D object at 0x7f5385fc8940> False
<keras.layers.convolutional.Conv2D object at 0x7f5385f6e668> False
<keras.layers.convolutional.Conv2D object at 0x7f5385f6e748> False
<keras.layers.pooling.MaxPooling2D object at 0x7f5385f7cba8> False
<keras.layers.convolutional.Conv2D object at 0x7f5385f237f0> False
<keras.layers.convolutional.Conv2D object at 0x7f5385f238d0> False
<keras.layers.convolutional.Conv2D object at 0x7f5385f39d68> False
<keras.layers.pooling.MaxPooling2D object at 0x7f5385f5bc18> False
<keras.layers.convolutional.Conv2D object at 0x7f5385efed30> False
<keras.layers.convolutional.Conv2D object at 0x7f5385efe9e8> False
<keras.layers.convolutional.Conv2D object at 0x7f5385f10748> False
<keras.layers.pooling.MaxPooling2D object at 0x7f5385ea4780> False
<keras.layers.convolutional.Conv2D object at 0x7f5385ec6d68> True
<keras.layers.convolutional.Conv2D object at 0x7f5385eda320> True
<keras.layers.convolutional.Conv2D object at 0x7f5385e6c198> True
<keras.layers.pooling.MaxPooling2D object at 0x7f5385e7b6a0> True
```

Şekil IV.10. Transfer öğrenme için kullanılan VGG16 isimli yapay sinir ağının son 4 katmanı hariç diğer katmanları dondurulmuştur.

Evrişim katmanlarından sonra Tam Bağlantı katmanında yine aktivasyon fonksiyonu olarak Relu kullanılıyor. Çıkış katmanında ise sınıflandırma amaçlı Softmax fonksiyonu kullanılıyor. Modelin tamamında 14.847.554 adet parameter hesaplanıyor.

Mevcut veri setini eldeki görüntüler kullanılarak çoğaltmak için döndürme, yakınlaştırıp uzaklaştırma ve aynalama yöntemleri kullanılıyor.



Şekil IV.11. Veri çoğaltma işlemi uygulandıktan sonra sınıf bilgisi, en ölçüsü, boy ölçüsü ve kanal sayısı bilgisiyle örnek görüntüler.

Modelin eğitimi sonrası elde edilen bilgi .h5 doaya formatındaki model dosyasında yerel diske saklanıyor.

30 devirden (epoch) oluşan örnek bir eğitimin ilk 5 devri aşağıda gösterilmiştir. Buna göre her devirde eğitim ve sınama başarıımı artarken, eğitim ve sınama kaybı azalmaktadır.

Epoch 1/30

4843/4843 [=====] - 552s 114ms/step - loss: 0.4369 - acc: 0.7763 - val\_loss: 0.3931 - val\_acc: 0.8054

Epoch 2/30

4843/4843 [=====] - 552s 114ms/step - loss: 0.4039 - acc: 0.8008 - val\_loss: 0.3794 - val\_acc: 0.8165

Epoch 3/30

4843/4843 [=====] - 552s 114ms/step - loss: 0.3890 - acc: 0.8111 - val\_loss: 0.3687 - val\_acc: 0.8232

Epoch 4/30


4843/4843 [=====] - 553s 114ms/step - loss:

0.3811 - acc: 0.8166 - val\_loss: 0.3621 - val\_acc: 0.8258


Epoch 5/30

4843/4843 [=====] - 553s 114ms/step - loss:

0.3751 - acc: 0.8206 - val\_loss: 0.3582 - val\_acc: 0.8297




Şekil IV.12. 30 devirden (epoch) oluşan eğitimde, eğitim ve sınama başarımlarının zamanla değişimi grafiği.



Şekil IV.13. 30 devirden (epoch) oluşan eğitimde, eğitim ve sınama kaybının zamanla değişimi grafiği.

accuracy: 0.8333660259392739

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| Non-WMH(-)   | 0.90      | 0.84   | 0.87     | 6694    |
| WMH(+)       | 0.73      | 0.83   | 0.77     | 3502    |
| micro avg    | 0.83      | 0.83   | 0.83     | 10196   |
| macro avg    | 0.81      | 0.83   | 0.82     | 10196   |
| weighted avg | 0.84      | 0.83   | 0.84     | 10196   |




Şekil IV.14. Test veri seti ile yapılan tahminlerdeki karışıklığı gösteren Confusion Matrix ve tahminler sonucu hesaplanan doğruluk, hassasiyet, hatırlama ve f1 skor değerleri.

#### 4.4. Web Tabanlı Test Uygulaması

Bu çalışmada YSA eğitim sürecini yeniden yürütmeyen ancak eğitim sonrası elde edilen model dosyasını kullanan bir web tabanlı test uygulaması geliştirilmiştir. Web tabanlı test uygulaması ile eğitim sürecinde hiç kullanılmamış verilerle değerlendirmeler yapılmıştır.

Web tabanlı olan bu test uygulaması için Flask isimli web çatısı kullanılmıştır [29]. nii uzantılı orijinal veri setindeki görüntüler float64 veri tipindedir. Bu bağımsız test uygulamasında verilerde kayıp olmaması için web formundan yüklenen bir görüntü dosyası yerine hasta ve slice numarası kullanarak arka planda sıkıştırılmış numpy dizi şeklinde duran veri çağırılmaktadır.



The screenshot shows a web browser window with the address bar displaying '192.168.10.19:5000/'. The page contains a form with two input fields: 'Patient No:' and 'Slice No:'. Below these fields is a 'Gönder' (Send) button. The browser's address bar also shows a security warning icon and the URL '192.168.10.19:5000'.

Şekil IV.15. Web tabanlı test uygulamasının veri giriş ekranı.

#### 4.5. Web Tabanlı Test Uygulamasının Çıktılarının Renklendirilmesi

Değerlendirme amaçlı web tabanlı test uygulamasına yüklenen MR kesitleri üzerindeki pikseller sınıflandırılmakta ve tahmin sonucuna göre renklendirilmektedir.

Web tabanlı test uygulamasının verdiği çıktıdaki değerlerin açıklamaları aşağıdaki gibidir.

**Değerlendirilen toplam piksel sayısı:** Hesapladığım kontur içerisinde kalan piksel sayısı.

**WMH olarak sınıflandırılan piksel sayısı:** İleride lezyon oluşacağı tahmin edilen piksel sayısı. Bu pikseller kırmızı renkle işaretlenmiştir.

**Doğru tahmin edilen TP piksel sayısı:** Kesin referans pikseller ile kırmızı piksellerin örtüştüğü pikseller. Bu pikseller yeşil renkle işaretlenmiştir.

**Yanlış tahmin edilen FN piksel sayısı:** Kesin referans pikseller ile kırmızı piksellerin örtüşmediği pikseller. Bu pikseller mavi renkle işaretlenmiştir.

$$\text{Accuracy} = (TP+TN) / (TP+FP+TN+FN)$$

$$\text{Precision} = TP / (TP+FP)$$

$$\text{Recall} = TP / (TP+FN)$$


$$F1=2*(\text{Precision}*\text{Recall}) / (\text{Precision}+\text{Recall})$$

TP = WMH olacağı doğru tahmin edilen alanlar. Kırmızı ile yeşilin kesişimi.

TN = WMH olmayacağı doğru tahmin edilen alanlar. Gri ile mavini farkı.


FP = WMH olacağı yanlış tahmin edilen alanlar. Gri ile mavinin kesişimi ve kalan kırmızılar.

FN = WMH olmayacağı yanlış tahmin edilen alanlar. Gri ile mavinin kesişimi.




Degerlendirilen toplam piksel sayisi: 44211  
 WMH olarak siniflandirilan piksel sayisi: 7102  
 Dogru tahmin edilen TP(Yesil) piksel sayisi: 244  
 Yanlis tahmin edilen FN(Mavi) piksel sayisi: 28  
 Accuracy: 0.8437125613146771  
 Precision: 0.03422159887798037  
 Recall: 0.8970588235294118  
 F1: 0.06592812753309917

( a )



( b )



( c )

Şekil IV.16. Patient1 isimli hastanın 29. kesiti için web tabalı test uygulamasının görsel ve sayısal çıktıları ( a ), Kesite ait işaretlenmiş kesin referans pikseller ( b ), Görsel çıktının yakınlaştırılmış bir parçası ( c )

## V. UZMAN SİSTEMİN İYİLEŞTİRİLMESİNE YÖNELİK ÖNERİLER

Tasarlanan uzman sistemin başarımını iyileştirmek için veri setinin miktarında, yapısında, seçiminde ve ağıın eğitimindeki kullanım biçiminde değişik seçenekler önerilmiştir. Yine başarımı iyileştirmek için ağıın eğitiminde kullanılan hiper parametrelerde alternatif seçenekler denenmiştir. Bu çalışmada ayrıca kullanılan VGG16 modeli yerine farklı bir model olan ResNet50 modeli de denemiştir.

### 5.1. Denek Sayısındaki Değişimin Etkisi

Veri setimiz toplamda 20 hastadan alınan beyin MR görüntülerinden oluşmaktadır. Bu denemede hasta sayısının 18'e düşürülerek azaltılmasının başarımına etkisi test ediliyor.

Hasta Sayısı 20

1.140 Adet Axial Düzlemde MR Kesiti

70.408 Adet WMH Görüntü Yaması

140.816 Adet Non-WMH Görüntü Yamaları Dahil Toplam Yama Sayısı

Hasta Sayısı 18

1.022 Adet Axial Düzlemde MR Kesiti

67.972 Adet WMH Görüntü Yaması

135.944 Adet Non-WMH Görüntü Yamaları Dahil Toplam Yama Sayısı

Tablo V.1. Denek sayısındaki değişimin test veri seti üzerindeki etkisi.

| DURUM    | Accuracy | Precision | Recall | F1-Score |
|----------|----------|-----------|--------|----------|
| 20 Hasta | 0,790    | 0,79      | 0,79   | 0,79     |
| 18 Hasta | 0,801    | 0,80      | 0,80   | 0,80     |


Her iki durum için arada anlamlı bir fark görünmemekle beraber. Test edilen kesitin de sürece dahil edildiği 20 hastayla yapılan eğitimin daha iyi sonuç vermesi beklenirken %1 farkla daha kötü sonuç verdi.

Bu durum, rastgele üretilen koordinatlardan elde edilen yamaların rastgele etkisinden veya çıkarılan hastalara ait görüntülerin temsilinin iyi yönde olmamasından kaynaklanabileceği değerlendirildi.


## 5.2. Görüntü Yamalarının Normalize Edilmesinin Etkisi

.nii dosya formatında tutulan MR görüntüleri 64 bit'tir. Ancak kullandığımız YSA 8 bit görüntüler ile çalışmaktadır. Bu nedenle YSA'ya görüntü yamalarını 8 bit'e dönüştürerek veriyoruz. Bu denemede float64 olan veri tipinin doğrudan uint8'e dönüştürülmesi 1. Durum, OpenCV kütüphanesinin normalize fonksiyonuyla 8 bite'e dönüştürülmesi 2. Durum olarak ifade ediliyor. 1. ve 2. durumun eğitim sonucuna etkisi karşılaştırılıyor.

Orjinal float64 veri tipindeki bir görüntüde piksel değeri 904.7709205653051 olan örnek bir pikselin 1. Durumda değeri 136, 2. Durumda ise değeri 107 olmaktadır.



Şekil V.1. Float64 tipindeki rastgele örnek görüntü yamalarının 8 bit'e doğrudan dönüştürülmüş hali.



Şekil V.2. Float64 tipindeki rastgele örnek görüntü yamalarının OpenCV ile normalize edilerek 8 bit'e dönüştürülmüş hali.

Tablo V.2. Görüntü yamalarının normalize edilmesinin test veri seti üzerindeki etkisi.

| DURUM    | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|----------|----------|---------------------|------------------|--------------------|
| 1. Durum | 0,790    | 0,79                | 0,79             | 0,79               |
| 2. Durum | 0,845    | 0,85                | 0,85             | 0,85               |

### 5.3. Görüntü Yamalarının Farklı Yöntemlerle Normalize Edilmesinin Etkisi

Bu denemede görüntü yamaları YSA'ya verilmeden önce her yama kendi içinde farklı yöntemlerle normalize ediliyor. Normalize edilen kanallar farklı sıralarda dizilerek 3 kanallı görüntüler elde ediliyor ve elde edilen bu görüntülerle yapılan eğitimlerin sonuçları karşılaştırılıyor.

1. Durum: OpenCV kütüphanesinin normalize fonksiyonu kullanıldı.

Kanal Dizilimi: Durum1, Durum1, Durum1

2. Durum: Değeri 0'dan küçük olan piksellerin değerleri 0'a eşitlendi ve OpenCV normalize fonksiyonu kullanıldı.

Kanal Dizilimi: Durum2, Durum2, Durum2

3. Durum: Değeri 0'dan küçük olan piksellerin değerleri 0'a eşitlendi ve img girdi görüntüsünden aşağıdaki gibi new\_img çıktı görüntüsü elde edildi.

$$\text{new\_img} = (255 * \text{img} / \text{imax}).\text{astype}(\text{target\_type})$$

Kanal Dizilimi: Durum3, Durum3, Durum3

4. Durum: Değeri 0'dan küçük olan piksellerin değerleri 0'a eşitlendi ve img girdi görüntüsünden aşağıdaki gibi new\_imgY çıktı görüntüsü elde edildi.

$$\text{new\_imgY} = (((255 * \text{img} / \text{imax}) - \text{new\_img}) * 31).\text{astype}(\text{target\_type})$$

Kanal Dizilimi: Durum3, Durum3, Durum4

5. Durum: Değeri 0'dan küçük olan piksellerin değerleri 0'a eşitlendi ve img girdi görüntüsünden aşağıdaki gibi new\_imgB çıktı görüntüsü elde edildi.

$$\text{new\_imgB} = ((2047 * \text{img} / \text{imax}) \% 256).\text{astype}(\text{target\_type})$$

Kanal Dizilimi: Durum3, Durum3, Durum5

6. Durum: Durum3'ten farklı olarak elde edilen 3 kanallı görünür OpenCV normalize fonksiyonu ile tekrar normalize edildi.

7. Durum: Değeri 0'dan küçük olan piksellerin değerleri 0'a eşitlendi ve img girdi görüntüsünden aşağıdaki gibi new\_imgB2 çıktı görüntüsü elde edildi.

$$\text{new\_imgB2} = (240 + ((2047 * \text{img} / \text{imax}) \% 16)).\text{astype}(\text{target\_type})$$

Kanal Dizilimi: Durum3, Durum3, Durum7

8. Durum7'den farklı olarak farklı bir kanal dililimi uygulandı.

Kanal Dizilimi: Durum7, Durum3, Durum7

Tablo V.3. Normalizasyon yöntemindeki değişimin test veri seti üzerindeki etkisi.

| DURUM    | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|----------|----------|---------------------|------------------|--------------------|
| 1. Durum | 0,849    | 0,85                | 0,85             | 0,85               |
| 2. Durum | 0,850    | 0,85                | 0,85             | 0,85               |
| 3. Durum | 0,855    | 0,86                | 0,86             | 0,86               |
| 4. Durum | 0,849    | 0,85                | 0,85             | 0,85               |
| 5. Durum | 0,806    | 0,82                | 0,81             | 0,81               |
| 6. Durum | 0,849    | 0,85                | 0,85             | 0,85               |
| 7. Durum | 0,853    | 0,85                | 0,85             | 0,85               |
| 8. Durum | 0,842    | 0,84                | 0,84             | 0,84               |

#### 5.4. Veri Setindeki Eğitim, Doğrulama ve Test Oranlarındaki Değişimin Etkisi

Bu denemede veri setinde test için ayrılmış verilerin oranının başlangıçtaki oran olan %20'den %5'e düşürülmesinin etkisi gözlemlenmiştir.

1. Durum: Tüm görüntü yamalarının %64'ü eğitim, %16'sı doğrulama ve %20'si test için ayrıldı.
2. Durum: Tüm görüntü yamalarının %76'sı eğitim, %19'u doğrulama ve %5'i test için ayrıldı.

Tablo V.4. Veri setindeki oranların değişimin test verisi üzerindeki etkisi.

| DURUM    | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|----------|----------|---------------------|------------------|--------------------|
| 1. Durum | 0,855    | 0,86                | 0,86             | 0,86               |
| 2. Durum | 0,865    | 0,87                | 0,87             | 0,87               |


### 5.5. Devir (Epoch) Sayısının Artırılmasının Etkisi

Bu denemede diğer koşullar sabitken eğitimdeki devir sayısını artırmanın etkisi test veri seti ile değerlendirilmiştir.


1. Durum: Devir sayısı 20 dir.
2. Durum: Devir sayısı 30 dur.

Tablo V.5. Eğitimdeki devir sayısındaki değişimin test verisi üzerindeki etkisi.

| DURUM    | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|----------|----------|---------------------|------------------|--------------------|
| 1. Durum | 0,865    | 0,87                | 0,87             | 0,87               |
| 2. Durum | 0,875    | 0,88                | 0,88             | 0,88               |



Şekil V.3. 20 devirlik bir eğitimde (a) ve 30 devirlik bir eğitimde (b) eğitim ve doğrulama doğruluk değerlerinin devirler boyunca değişimi grafikleri.



Şekil V.4. 20 devirlik bir eğitimde (a) ve 30 devirlik bir eğitimde (b) eğitim ve doğrulama kayıp değerlerinin devirler boyunca değişimi grafikleri.

20 devirlik eğitimde en yüksek eğitim doğruluk değeri 0,8429 ile 20. devirde, en yüksek doğrulama doğruluk değeri 0,8597 ile 19. devirde gerçekleşti. En düşük eğitim kayıp değeri 0,3311 ile 20. devirde, en düşük doğrulama kayıp değeri 0,3025 ile 19. devirde gerçekleşti.

30 devirlik eğitimde en yüksek eğitim doğruluk değeri 0,8547 ile 29. devirde, en yüksek doğrulama doğruluk değeri 0,8709 ile 30. devirde gerçekleşti. En düşük eğitim kayıp değeri 0,3121 ile 27. devirde, en düşük doğrulama kayıp değeri 0,2824 ile 30. devirde gerçekleşti.

#### **5.6. Non-WMH Veri Setini Oluşturmak İçin Rastgele Seçilen Pikseller Arasına Belirli Bir Mesafe Konulmasının Etkisi**

Bu denemede Non-WMH veri setini oluşturan ve rastgele belirlenen pikselleri merkezine alan görüntü yamalarının merkezleri arasında en az belli bir mesafe olmasının etkisi değerlendirilmiştir. Bunun için mesafe 7 pikselden yakın olmayacak şekilde rastgele koordinatlar belirlenmiştir. Ancak bu durumda dar alanda çok sayıda piksel üretilmediğinden belli bir zamandan sonra yeni koordinat üretilmemiştir. Mesafe 5 pikselden yakın olmayacak şekilde denendiğinde daha ileri bir aşamada yine aynı nedenden yeni koordinat üretilmemiştir. Mesafe 3 pikselden yakın olmayacak şekilde denendiğinde tüm kesitlerde, tüm yamalar için merkez koordinatlar üretilebilmiştir.

1. Durum: Rastgele üretilen merkez koordinatlar arasında mesafe kontrolü yok.
2. Durum: Rastgele üretilen merkez koordinatlar arasındaki mesafe 3 pikselden yakın olmasın.

Tablo V.6. Rastgele üretilen merkez koordinatlar arası mesafe kontrolünün test verisi üzerindeki etkisi.

| DURUM    | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|----------|----------|---------------------|------------------|--------------------|
| 1. Durum | 0,875    | 0,88                | 0,88             | 0,88               |
| 2. Durum | 0,868    | 0,87                | 0,87             | 0,87               |

### 5.7. Görüntü Yamalarını Büyütürken Kullanılan Farklı Yöntemlerin Etkileri

WMH ve Non-WMH görüntü yamaları orjinal görüntüden 21x21 ebatlarında alınmakta ve kullandığımız modelin kabul ettiği en küçük boyut olan 48x48 ebatına büyütülmektedir. Büyütme işlemi OpenCV kütüphanesinin resize fonksiyonu ile yapılmaktadır. Resize fonksiyonundaki interpolation parametresi farklı değerler alabilmektedir. Bu deneyde kullanılan interpolation yönteminin sonuca etkisi değerlendirilmektedir.

Tablo V.7. Görüntü yamalarını büyütürken kullanılan yöntemin doğruluğa etkisi.

| Interpolation Yöntemi | 20 Devirde Elde Edilen En Yüksek Eğitim Doğruluğu | Test Verisi Üzerinde Elde Edilen Doğruluk |
|-----------------------|---------------------------------------------------|-------------------------------------------|
| INTER_AREA            | 0,845                                             | 0,865                                     |
| INTER_LANCZOS4        | 0,843                                             | 0,866                                     |
| INTER_LINEAR          | 0,840                                             | 0,858                                     |
| INTER_NEAREST         | 0,839                                             | 0,860                                     |
| INTER_CUBIC           | 0,833                                             | 0,855                                     |

Interpolation yöntemi INTER\_AREA ve diğer tüm şartlar aynı iken devir sayısının önce 30 sonra 50 yapılmasının doğruluğa doğru oranda etki yaptığı gözlemlenmiştir.

Tablo V.8. Devir sayısının 30 olması durumundaki doğruluk değerleri.

| Interpolation Yöntemi | 30 Devirde Elde Edilen En Yüksek Eğitim Doğruluğu | Test Verisi Üzerinde Elde Edilen Doğruluk |
|-----------------------|---------------------------------------------------|-------------------------------------------|
| INTER_AREA            | 0,852                                             | 0,875                                     |

Tablo V.9. Devir sayısının 50 olması durumundaki doğruluk değerleri.

| Interpolation Yöntemi | 50 Devirde Elde Edilen En Yüksek Eğitim Doğruluğu | Test Verisi Üzerinde Elde Edilen Doğruluk |
|-----------------------|---------------------------------------------------|-------------------------------------------|
| INTER_AREA            | 0,860                                             | 0,880                                     |

### 5.8. Aynı Veri Seti İle VGG16 Yerine ResNet50 Kullanmanın Etkisi

Denemelerde kullanılan Keras versiyonundaki uyumsuzluklardan dolayı bu deneme Google Colaboratory isimli bulut ortamında yapılmıştır.

VGG16 ile yapıldığı gibi ImageNet veri seti ile de transfer öğrenme yöntemi kullanılmıştır. Bunun için modelin son 5 katmanı hariç dondurulmuştur.

Tablo V.10. Kullanılan modelin test verisi üzerindeki etkisi.

| Model    | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|----------|----------|---------------------|------------------|--------------------|
| VGG16    | 0,875    | 0,88                | 0,88             | 0,88               |
| ResNet50 | 0,821    | 0,82                | 0,82             | 0,82               |

### 5.9. Yama Boyutlarını FatPixel Yöntemiyle Büyütmenin Etkisi

Bu denemede 21x21 piksel boyutlarındaki görüntü yamalarını OpenCV kütüphanesinin resize fonksiyonu ile 48x48 piksel boyutlarına büyütme yerine

FatPixel olarak isimlendirdiğimiz, görüntü yamasındaki her bir pikselin en ve boy uzunluklarını 3 katına çıkararak 63x63 piksel boyutlarına büyütmenin etkisi değerlendirildi.

Tablo V.11. Diğer Bütün koşullar aynı iken kullanılan yama büyütme yönteminin test verisi üzerindeki etkisi.


| Yama Büyütme Yöntemi | Accuracy | Precision (Avg.) | Recall (Avg.) | F1-Score (Avg.) |
|----------------------|----------|------------------|---------------|-----------------|
| OpenCV Resize        | 0,866    | 0,88             | 0,87          | 0,87            |
| FatPixel             | 0,858    | 0,86             | 0,86          | 0,86            |

#### 5.10. Linear veya Piecewise-Linear1 Normalizasyon Yöntemi Kullanmanın Etkisi

Bu denemede görüntü yamaları FatPixel yöntemi ile büyütülüp, modele 30 devirlik bir eğitim yaptırılmaktadır ve tüm koşullar aynı iken Linear ve Piecewise-Linear1 yöntemlerinin piksel sınıflandırmaya etkisi değerlendirilmektedir.

Piecewise-Linear1 normalizasyon yönteminde her bir tek kanallı görüntü yamasının kendi içerisindeki piksellerin değerlerinin histogramı çıkarılıyor. İkinci tepe değere karşılık gelen piksel değeri imaximum değişkenine atanıyor.

Linear Normalizasyon yönteminde her bir tek kanallı görüntü yamasındaki en büyük piksel değeri imax değişkeninde tutuluyor.



Şekil V.5. Patient10 isimli hastanın axial düzlemdeki 30 numaralı kesitinin görüntüsü (a), bu kesitin gri değerlerini ve karşılık gelen piksel sayılarını gösterir histogramı (b), bu kesitteki KR piksellerin histogramı (c)

Linear Normalizasyon Kod Parçası:

```
imax = img.max()

new_img = (255* img /imax).astype(target_type)
```

Picewise-Linear1 Normalizasyon Kod Parçası:

```
orj_pixel_value=greyimg[yy,xx]

if(orj_pixel_value<(imaximum-200)):

    new_pixel_value=interp(orj_pixel_value,[0,(imaximum-200)],[0,56])

elif(orj_pixel_value<imaximum):

    new_pixel_value=interp(orj_pixel_value,[(imaximum-
200),imaximum],[56,255])

elif(orj_pixel_value<(imaximum+200)):

    new_pixel_value=interp(abs(orj_pixel_value-imaximum-
200),[0,200],[56,255])


else:

    new_pixel_value=interp(abs(orj_pixel_value-imaximum-200-
maximum),[0,maximum],[0,56])

pozitifimg[yy,xx]=new_pixel_value
```

Tablo V.12. Kullanılan iki farklı normalizasyon yönteminin test verisi üzerindeki etkisi.

| Normalizasyon<br>Yöntemi | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|--------------------------|----------|---------------------|------------------|--------------------|
| Linear                   | 0,858    | 0,86                | 0,86             | 0,86               |
| Picewise-Linear1         | 0,826    | 0,83                | 0,83             | 0,83               |



Şekil V.6. Patient1 isimli hastanın axial düzlemdeki 29. kesitindeki piksellerin web tabalı test uygulamasıyla sınıflandırılması sonucu elde edilen görüntüler ve istatistiksel değerler. Linear Normalizasyon yöntemi ile elde edilen çıktı ( a ), Piecewise-Linear1 yöntemi ile elde edilen çıktı ( b )

### 5.11. Piecewise-Linear1 Normalizasyon Yönteminde Yama Boyutunu Büyütme Yöntemlerinin Etkisi

1.Durum: OpenCV kütüphanesinin resize fonksiyonu ile görüntü yamaları 48x48 boyutlarına büyütülüyor.

2.Durum: FatPixel yöntemi ile görüntü yamaları 63x63 boyutlarına büyütülüyor.

Tablo V.13. Piecewise-Linear1 normalizasyon yönteminde yama büyütme yönteminin test verisi üzerindeki etkisi.

| Durum   | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|---------|----------|---------------------|------------------|--------------------|
| 1.Durum | 0,830    | 0,83                | 0,83             | 0,83               |
| 2.Durum | 0,826    | 0,83                | 0,83             | 0,83               |

Tablo V.14. Piecewise-Linear1 normalizasyon yönteminde yama büyütme yönteminin web tabanlı test uygulamasındaki etkisi.

| Durum   | Hasta/Kesit      | Accu. | Prec. | Reca. | F1    |
|---------|------------------|-------|-------|-------|-------|
| 1.Durum | Patient1/Slice29 | 0,889 | 0,033 | 0,617 | 0,064 |
| 2.Durum | Patient1/Slice29 | 0,903 | 0,038 | 0,617 | 0,073 |

### 5.12. Piecewise-Linear1 ile Piecewise-Linear2 Normalizasyon Yöntemlerinin Karşılaştırması

Picewise-Linear2 Normalizasyon Kod Parçası:

```

    orj_pixel_value=greyimg[yy,xx]

    if(orj_pixel_value<(imaximum-200)):

        new_pixel_value=interp(orj_pixel_value,[0,(imaximum-200)],[0,22])

    elif(orj_pixel_value<(imaximum+200)):

        new_pixel_value=interp(orj_pixel_value,[(imaximum-
200),(imaximum+200)],[22,221])

    else:

        new_pixel_value=interp(orj_pixel_value,[(imaximum+200),maximum],[221,2
55])

    pozitifimg[yy,xx]=new_pixel_value

```

Tablo V.15. Piecewise-Linear1 ve Piecewise-Linear2 normalizasyon yöntemlerinin test verisi üzerindeki etkisi.

| Yöntem                | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|-----------------------|----------|---------------------|------------------|--------------------|
| Piecewise-<br>Linear1 | 0,826    | 0,83                | 0,83             | 0,83               |
| Piecewise-<br>Linear2 | 0,843    | 0,84                | 0,84             | 0,84               |

Tablo V.16. Piecewise-Linear1 ve Piecewise-Linear2 normalizasyon yöntemlerinin web tabanlı test uygulamasındaki etkisi.

| Yöntem            | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|-------------------|-------------------|-------|-------|-------|-------|
| Piecewise-Linear1 | Patient1/Slice29  | 0,903 | 0,038 | 0,617 | 0,073 |
| Piecewise-Linear2 | Patient1/Slice29  | 0,912 | 0,034 | 0,492 | 0,064 |
| Piecewise-Linear1 | Patient20/Slice40 | 0,701 | 0,007 | 0,691 | 0,014 |
| Piecewise-Linear2 | Patient20/Slice40 | 0,742 | 0,008 | 0,654 | 0,016 |

### 5.13. Web Tabanlı Test Uygulamasında Test İçin Kullanılan Verideki

#### Değişikliğin Etkisi

Bu denemede modelin eğitimi, doğrulaması ve testi için kullanılan verilerden ayrılıp yalnızca web tabanlı test uygulaması üzerinde test etmek için saklanan verilerde değişikliğe gidilmiştir.

#### 1.Durum:

Model İle Kullanılan Hasta Görüntüleri: Patient2, Patient3, Patient4, Patient5, Patient6, Patient7, Patient8, Patient9, Patient10, Patient11, Patient12, Patient13, Patient14, Patient15, Patient16, Patient17, Patient18, Patient19

Web tabanlı Test Uygulamasında Kullanılan Hasta Görüntüleri: Patient1, Patient20

## 2.Durum:

Model İle Kullanılan Hasta Görüntüleri: Patient1, Patient2, Patient3, Patient4, Patient5, Patient6, Patient7, Patient8, Patient9, Patient11, Patient12, Patient13, Patient14, Patient15, Patient16, Patient17, Patient18, Patient19


Web tabanlı Test Uygulamasında Kullanılan Hasta Görüntüleri: Patient10, Patient20

Tablo V.17. Model ve web tabanlı test uygulaması için kullanılacak verilerdeki değişikliğin test verisi üzerindeki etkisi.

| Durum   | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|---------|----------|---------------------|------------------|--------------------|
| 1.Durum | 0,826    | 0,83                | 0,83             | 0,83               |
| 2.Durum | 0,817    | 0,82                | 0,82             | 0,82               |

Tablo V.18. Model ve web tabanlı test uygulaması için kullanılacak verilerdeki değişikliğin web tabanlı test uygulamasındaki etkisi.

| Durum   | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|---------|-------------------|-------|-------|-------|-------|
| 1.Durum | Patient1/Slice29  | 0,903 | 0,038 | 0,617 | 0,073 |
| 2.Durum | Patient10/Slice29 | 0,748 | 0,007 | 0,750 | 0,014 |
| 1.Durum | Patient20/Slice40 | 0,701 | 0,007 | 0,691 | 0,014 |
| 2.Durum | Patient20/Slice40 | 0,679 | 0,007 | 0,703 | 0,014 |



Şekil V.7. Patient20 isimli hastanın axial düzlemdeki 40 numaralı kesitinin web tabanlı test uygulamasında değerlendirilmesinin sonuçları. 1.Durumun çıktısı (a), 2.Durumun çıktısı (c), 1.Durumun yakınlaştırılmış görüntüsü (b), 2.Durumun yakınlaştırılmış görüntüsü (d)

#### 5.14. Yama Boyutundaki Değişikliğin Etkisi

Denemelerde modelin eğitimi için şimdiye kadar merkezine KR pikseli ve rastgele belirlenmiş pikseli alan 21x21 boyutlarındaki görüntü yamaları kullanıldı. Bu denemede alternatif olarak 17x17 görüntü yamaları kullanmanın etkisi değerlendirildi.

Modelin eğitiminde kullanılacak görüntü yamaları Piecewise-Linear1 yöntemiyle normalize edildi ve FatPixel yöntemi ile boyutları 3 katına büyütüldü.

Tablo V.19. Modelin eğitimi için kullanılan yama boyutu değişikliğinin test verisi üzerindeki etkisi.

| Yama Boyutu | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|-------------|----------|---------------------|------------------|--------------------|
| 17 x 17     | 0,795    | 0,80                | 0,80             | 0,80               |
| 21 x 21     | 0,826    | 0,83                | 0,83             | 0,83               |

Tablo V.20. Modelin eğitimi için kullanılan yama boyutu değişikliğinin web tabanlı test uygulamasındaki etkisi.

| Yama Boyutu | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|-------------|-------------------|-------|-------|-------|-------|
| 17 x 17     | Patient1/Slice29  | 0,900 | 0,032 | 0,533 | 0,061 |
| 17 x 17     | Patient20/Slice40 | 0,718 | 0,006 | 0,580 | 0,013 |
| 21 x 21     | Patient1/Slice29  | 0,903 | 0,038 | 0,617 | 0,073 |
| 21 x 21     | Patient20/Slice40 | 0,701 | 0,007 | 0,691 | 0,014 |

### 5.15. Piecewise-Linear1 ile Treshold1 Normalizasyon Yöntemlerinin

#### Karşılaştırması

Treshold1 normalizasyon yönteminde tüm hastaların, tüm axial düzlemdeki kesitlerindeki KR piksellerin en küçük ve en büyük değerleri kontrol edilerek en küçük 157 ve en büyük 1783 olacak şekilde bir aralık belirlendi. Bu aralığın altındaki ve üstündeki değerler 0'a eşitlendi. Aralıktaki değerler ise 1-255 aralığındaki değerlere eşitlendi.

Treshold1 Normalizasyon Kod Parçası:

```
orj_pixel_value=round(greying[yy,xx])
```

```
new_pixel_value=interp(orj_pixel_value,[157,1783],[1,255])
```

```
pozitifimg[yy,xx]=new_pixel_value
```

Tablo V.21. Piecewise-Linear1 ve Treshold1 normalizasyon yöntemlerinin test verisi üzerindeki etkisi.

| Yöntem            | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|-------------------|----------|---------------------|------------------|--------------------|
| Piecewise-Linear1 | 0,826    | 0,83                | 0,83             | 0,83               |
| Treshold1         | 0,850    | 0,85                | 0,85             | 0,85               |

Tablo V.22. Piecewise-Linear1 ve Treshold1 normalizasyon yöntemlerinin web tabanlı test uygulamasındaki etkisi.

| Yöntem | Hasta/Kesit | Accu. | Prec. | Reca. | F1 |
|--------|-------------|-------|-------|-------|----|
|--------|-------------|-------|-------|-------|----|

|                   |                   |       |       |       |       |
|-------------------|-------------------|-------|-------|-------|-------|
| Piecewise-Linear1 | Patient1/Slice29  | 0,903 | 0,038 | 0,617 | 0,073 |
| Treshold1         | Patient1/Slice29  | 0,948 | 0,022 | 0,176 | 0,040 |
| Piecewise-Linear1 | Patient20/Slice40 | 0,701 | 0,007 | 0,691 | 0,014 |
| Treshold1         | Patient20/Slice40 | 0,776 | 0,012 | 0,888 | 0,025 |

### 5.16. Yama Boyutu 17x17 İken Veri Seti Oranındaki ve Normalizasyon

#### Yöntemindeki Değişimin Etkileri

Bu denemede 17x17 boyutundaki görüntü yamalarının FatPixel yöntemi ile 51x51 boyutuna büyütüldüğü ve her görüntü yamasının kendi içinde Piecewise-Linear1 yöntemi ile normalize edildiği durumda modelin eğitiminde kullanılan tüm görüntü yamaları içerisindeki WMH yama sayısının Non-WMH yama sayısına oranındaki değişimin etkisi değerlendirilmiştir.

Tablo V.23. WMH, Non-WMH oranındaki değişimin test verisi üzerindeki etkisi.

| WMH/Non-WMH Oranı | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|-------------------|----------|---------------------|------------------|--------------------|
| 1/1               | 0,802    | 0,81                | 0,80             | 0,80               |
| 1/2               | 0,795    | 0,80                | 0,80             | 0,80               |

Tablo V.24. WMH, Non-WMH oranındaki deęişimin web tabanlı test uygulamasındaki etkisi.

| WMH/Non-WMH Oranı | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|-------------------|-------------------|-------|-------|-------|-------|
| 1/1               | Patient1/Slice29  | 0,759 | 0,017 | 0,705 | 0,034 |
| 1/2               | Patient1/Slice29  | 0,900 | 0,032 | 0,533 | 0,061 |
| 1/1               | Patient20/Slice40 | 0,610 | 0,006 | 0,740 | 0,012 |
| 1/2               | Patient20/Slice40 | 0,718 | 0,006 | 0,580 | 0,013 |

WMH/Non-WMH Oranı  $\frac{1}{2}$  iken ve dięer tüm koşullar sabitken Piecewise-Linear1 normalizasyon yöntemi yerine Treshold1 yöntemi kullanılmasının etkisi aşığıdaki Tablo V.25. ve Tablo V.26. ile gösterilmiştir.

Tablo V.25. WMH, Non-WMH oranının  $\frac{1}{2}$  olduęu durumda normalizasyon yöntemindeki deęişimin test verisi üzerindeki etkisi.


| Normalizasyon Yöntemi | Accuracy | Precision (Avg.) | Recall (Avg.) | F1-Score (Avg.) |
|-----------------------|----------|------------------|---------------|-----------------|
| Piecewise-Linear1     | 0,795    | 0,80             | 0,80          | 0,80            |
| Treshold1             | 0,835    | 0,84             | 0,84          | 0,84            |

Tablo V.26. WMH, Non-WMH oranının  $\frac{1}{2}$  olduğu durumda normalizasyon yöntemindeki değişimin web tabanlı test uygulamasındaki etkisi.

| Normalizasyon Yöntemi | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|-----------------------|-------------------|-------|-------|-------|-------|
| Piecewise-Linear1     | Patient1/Slice29  | 0,900 | 0,032 | 0,533 | 0,061 |
| Treshold1             | Patient1/Slice29  | 0,942 | 0,034 | 0,316 | 0,062 |
| Piecewise-Linear1     | Patient20/Slice40 | 0,718 | 0,006 | 0,580 | 0,013 |
| Treshold1             | Patient20/Slice40 | 0,743 | 0,009 | 0,765 | 0,018 |

### 5.17. İki ve Üç Parçalı Normalizasyon Yöntemlerinin Etkisi

Treshold1 normalizasyon yönteminde tüm axail düzlemdeki kesitlerdeki KR piksellerin değerlerinin histogramı kullanılarak en küçük 157 ve en büyük 1738 değerleri belirlenip 1-255 aralığına eşitlenmişti. Bu durumda hassasiyet  $(1783-157)/255=6$  olarak hesaplanmaktadır. Hassasiyeti arttırmak bu histogramdaki tepe noktalarından faydalanıldı.



Şekil V.8. Axail düzlemdeki tüm kesitlerdeki KR piksellerin değerlerinin histogramı. Tepe noktaların gri değerleri sırayla: 95, 293, 491, 689, 887, 1085, 1283, 1481, 1697, 1877, 2075

2 Parçalı Normalizasyon Kod Parçası:

```
if (orj_pixel_value<157):
```

```
    new_pixel_value=0
```

```
elif(orj_pixel_value<492):
```

```
    new_pixel_value=interp(orj_pixel_value,[157,492],[1,255])
```

```
elif(orj_pixel_value<1783):
```

```
    new_pixel_value=interp(orj_pixel_value,[493,1783],[1,255])
```

```
elif(orj_pixel_value>1783):
```

```
    new_pixel_value=0
```

3 Parçalı Normalizasyon Kod Parçası:

```

if (orj_pixel_value<157):
    new_pixel_value=0
elif(orj_pixel_value<492):
    new_pixel_value=interp(orj_pixel_value,[157,491],[1,255])
elif(orj_pixel_value<888):
    new_pixel_value=interp(orj_pixel_value,[492,887],[1,170])
elif(orj_pixel_value<1784):
    new_pixel_value=interp(orj_pixel_value,[888,1783],[171,255])
elif(orj_pixel_value>1783):
    new_pixel_value=0

```

Tablo V.27. 2 parçalı ve 3 parçalı normalizasyon yöntemlerinin test verisi üzerindeki etkileri.

| Normalizasyon<br>Yöntemi | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|--------------------------|----------|---------------------|------------------|--------------------|
| 2 Parçalı                | 0,865    | 0,87                | 0,87             | 0,87               |
| 3 Parçalı                | 0,872    | 0,88                | 0,87             | 0,87               |

Tablo V.28. 2 parçalı ve 3 parçalı normalizasyon yöntemlerinin web tabanlı test uygulamasındaki etkisi.

| Normalizasyon<br>Yöntemi | Hasta/Kesit      | Accu. | Prec. | Reca. | F1    |
|--------------------------|------------------|-------|-------|-------|-------|
| 2 Parçalı                | Patient1/Slice29 | 0,860 | 0,020 | 0,463 | 0,039 |

|           |                   |       |       |       |       |
|-----------|-------------------|-------|-------|-------|-------|
| 3 Parçalı | Patient1/Slice29  | 0,863 | 0,024 | 0,558 | 0,047 |
| 2 Parçalı | Patient20/Slice40 | 0,884 | 0,005 | 0,197 | 0,010 |
| 3 Parçalı | Patient20/Slice40 | 0,877 | 0,005 | 0,197 | 0,010 |

### 5.18. Sigmoid Normalizasyon Yönteminin Etkisi

Bu denemede doğrusal olmayan sigmoid fonksiyonu kullanılarak her görüntü yamasının kendi içinde normalize edilmesinin etkisi değerlendiriliyor.

Sigmoid Normalizasyon Kod Parçası:

```
def sigmoid(x):
```

```
    s=1/(1+np.exp(-x))
```

```
    ds=s*(1-s)
```

```
    return ds
```

```
if (orj_pixel_value<157):
```

```
    new_pixel_value=0
```

```
elif(orj_pixel_value<493):
```

```
    mapped_pixel_value=interp(orj_pixel_value,[157,492],[-6,0])
```

```
    sig_pixel_value=sigmoid(mapped_pixel_value)*1020
```

```
    new_pixel_value=int(round(sig_pixel_value))
```

```
elif(orj_pixel_value<1784):
```

```
    mapped_pixel_value=interp(orj_pixel_value,[493,1783],[0,6])
```

```
    sig_pixel_value=sigmoid(mapped_pixel_value)*1020
```

```
    new_pixel_value=int(round(sig_pixel_value))
```

elif(orj\_pixel\_value>1783):

new\_pixel\_value=0

Tablo V.29. Sigmoid normalizasyon yöntemlerinin test verisi üzerindeki etkisi.

| Normalizasyon<br>Yöntemi | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|--------------------------|----------|---------------------|------------------|--------------------|
| Sigmoid                  | 0,872    | 0,88                | 0,87             | 0,87               |

Tablo V.30. Sigmoid normalizasyon yönteminin web tabanlı test uygulamasındaki etkisi.

| Normalizasyon<br>Yöntemi | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|--------------------------|-------------------|-------|-------|-------|-------|
| Sigmoid                  | Patient1/Slice29  | 0,893 | 0,033 | 0,584 | 0,062 |
| Sigmoid                  | Patient20/Slice40 | 0,794 | 0,009 | 0,592 | 0,018 |

### 5.19. Normalizasyonun Yama İçi Histogram Kullanılarak Yapılması İle Kesit İçi Histogram Kullanılarak Yapılması Durumunun Etkisi

Bu denemeye kadar normalizasyon, her görüntü yaması için ayrı ayrı ve yama içi piksel değerleri kullanılarak yapıldı. Bu denemede her MR kesiti kendi konturu içerisindeki piksel değerleri kullanarak ayrı ayrı normalize edildi. Ardından görüntü yamaları bu normalize edilmiş kesitlerden alındı ve doğrudan kullanıldı.

Kullanılan Linear Normalizasyon Kod Parçası:

```
if (T2image[yy,xx]<0):
```

```
    in_contour_pixels.append(0)
```

```
imax = np.array(in_contour_pixels).max()
```

```
normalized_pixels = (255* np.array(in_contour_pixels)/imax).astype(np.uint8)
```

Tablo V.31. Normalizasyon için kullanılan bölgenin test verisi üzerindeki etkisi.

| Normalizasyon Bölgesi/Türü | Accuracy | Precision (Avg.) | Recall (Avg.) | F1-Score (Avg.) |
|----------------------------|----------|------------------|---------------|-----------------|
| Yama İçi/Linear            | 0,866    | 0,88             | 0,87          | 0,87            |
| Kesit İçi/Linear           | 0,852    | 0,87             | 0,85          | 0,86            |

Tablo V.32. Normalizasyon için kullanılan bölgenin web tabanlı test uygulamasındaki etkisi.

| Normalizasyon Bölgesi/Türü | Hasta/Kesit      | Accu. | Prec. | Reca. | F1    |
|----------------------------|------------------|-------|-------|-------|-------|
| Yama İçi/Linear            | Patient1/Slice29 | 0,843 | 0,034 | 0,897 | 0,065 |
| Kesit İçi/Linear           | Patient1/Slice29 | 0,876 | 0,036 | 0,750 | 0,069 |

1.Durum: Yama içerisindeki piksel değerleri kullanılarak, Piecewise-Linear1 yöntemiyle normalizasyon yapılıyor. Yama boyutları FatPixel yöntemiyle 63x63 ebatlarına büyütülüyor.

2.Durum: Kesit içerisindeki piksel değerleri kullanılarak Piecewise-Linear1 yöntemiyle normalizasyon yapılıyor. Yama boyutları Resize fonksiyonuyla 48x48 ebatlarına büyütülüyor.

Tablo V.33. Piecewise-Linear1 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin test verisi üzerindeki etkileri.

| Durum   | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|---------|----------|---------------------|------------------|--------------------|
| 1.Durum | 0,826    | 0,83                | 0,83             | 0,83               |
| 2.Durum | 0,848    | 0,86                | 0,85             | 0,85               |

Tablo V.34. Piecewise-Linear1 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin web tabanlı test uygulamasındaki etkisi.

| Durum<br>Bölgesi/Türü | Hasta/Kesit      | Accu. | Prec. | Reca. | F1    |
|-----------------------|------------------|-------|-------|-------|-------|
| 1.Durum               | Patient1/Slice29 | 0,903 | 0,038 | 0,617 | 0,073 |
| 2.Durum               | Patient1/Slice29 | 0,842 | 0,024 | 0,647 | 0,048 |

3.Durum: Yama içerisindeki piksel değerleri kullanılarak, Piecewise-Linear2 yöntemiyle normalizasyon yapılıyor. Yama boyutları FatPixel yöntemiyle 63x63 ebatlarına büyütülüyor.

4.Durum: Kesit içerisindeki piksel değerleri kullanılarak Piecewise-Linear2 yöntemiyle normalizasyon yapılıyor. Yama boyutları Resize fonksiyonuyla 48x48 ebatlarına büyütülüyor.

Tablo V.35. Piecewise-Linear2 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin test verisi üzerindeki etkileri.

| Durum   | Accuracy | Precision<br>(Avg.) | Recall<br>(Avg.) | F1-Score<br>(Avg.) |
|---------|----------|---------------------|------------------|--------------------|
| 3.Durum | 0,843    | 0,84                | 0,84             | 0,84               |
| 4.Durum | 0,867    | 0,87                | 0,87             | 0,87               |

Tablo V.36. Piecewise-Linear2 normalizasyon için kullanılan bölgenin ve yama büyütme yönteminin web tabanlı test uygulamasındaki etkisi.

| Durum<br>Bölgesi/Türü | Hasta/Kesit       | Accu. | Prec. | Reca. | F1    |
|-----------------------|-------------------|-------|-------|-------|-------|
| 3.Durum               | Patient1/Slice29  | 0,912 | 0,034 | 0,492 | 0,064 |
| 4.Durum               | Patient1/Slice29  | 0,910 | 0,059 | 0,919 | 0,111 |
| 3.Durum               | Patient20/Slice40 | 0,742 | 0,008 | 0,654 | 0,016 |
| 4.Durum               | Patient20/Slice40 | 0,782 | 0,010 | 0,691 | 0,020 |

## VI. ÖNERİLEN YÖNTEMLERİN DEĞERLENDİRİLMESİ

Veri setini oluştururken kullanılan hasta sayısının 18 yerine 20 olmasını önerdiğimiz yöntemde modelin kendi içerisindeki testi için ayrılan veriler üzerindeki test sonucuna göre başarıma olumlu bir katkı sağlamadığı gözlemlenmiştir. Bu durumun eklenen 2 hastanın görüntülerin temsilinin iyi yönde olmamasından kaynaklanabileceği değerlendirilmiştir.

Görüntü yamalarını doğrudan 8 bite dönüştürüp modele vermek yerine her yamayı kendi içinde normalize ettikten sonra modele verilmesini önerdiğimiz yöntemin başarıma önemli ölçüde katkı sağladığı gözlemlenmiştir. Bu tespitten hareketle farklı normalizasyon yöntemlerinin katkısı değerlendirilmiştir.

Tablo V.3'te görülebileceği gibi 3.Durum olarak ifade edilen normalizasyon yöntemi ile test verisi üzerindeki Accuracy 0,855 seviyesine yükseltilebilmiştir.

Modelin kendi içerisindeki eğitimi, doğrulaması ve testi için kullanılan verilerin kendi arasındaki dağılımının değiştirilmesini önerdiğimiz yöntemde, test oranını azaltırken eğitim ve doğrulama oranını arttırmanın başarıma olumlu katkı sağladığı ve test verisi üzerindeki Accuracy değerinin 0,865 seviyesine yükseldiği gözlemlenmiştir.

Modelin eğitimindeki hiper parametrelerden olan devir sayısını 20'den 30'a çıkardığımız önerimiz olumlu bir katkı sağlayarak test verisi üzerindeki Accuracy

değerinin 0,875'e yükseldiği gözlemlenmiştir. Şekil V.3 ve Şekil V.4'teki grafiklerde de görülebileceği gibi her devirde eğitim ve doğrulama doğruluk değerleri artarken kayıp değeri azalmaktadır. Devir sayısını artırmak modelin eğitim süresini önemli ölçüde artırmaktadır.

İki sınıflı bu problemde önceden bilinen KR veriler yanında eğitim için modele KR-Değil veriler de vermek gerekmektedir. KR-Değil verileri belirli koşullarda rastgele üretmek yanında, ek olarak kendi aralarında belli bir mesafe olacak şekilde rastgele üretmek için önerilen bu yöntemde; Rastgele üretilen merkez koordinatlar arasındaki mesafenin 3 pikselden yakın olmaması koşulunun olumlu bir katkı sağlamadığı gözlemlenmiştir.

Veri setini oluştururken belirlediğimiz 21x21 görüntü yaması boyutlarını modelin kabul ettiği 48x48 ebatına büyütürken kullanılan yöntemlerden OpenCV kütüphanesinin resize fonksiyonunun interpolation parametresi için 5 farklı ön tanımlı seçeneğin etkileri karşılaştırıldı. INTER\_AREA seçeneği ile eğitim doğruluk oranında en yüksek değer elde edildiği gözlemlendi.

Kullanılan modeli değiştirmenin etkisini gözlemlemek için, VGG16 isimli model yerine benzer problemlerde yaygın kullanılan ResNet50 isimli modeli kullandığımız önerimizde modelin kendi içerisindeki test için ayrılan veriler üzerinde yapılan test sonucunda daha kötü sonuçlar verdiği gözlemlenmiştir.

Veri setini oluřtururken belirlediđimiz 21x21 g r nt  yaması boyutlarını modelin kabul ettiđi ebatlara y kseltirken OpenCV k t phanesinin resize fonksiyonunu kullanmak yerine yama i erisindeki her pikselin en boy uzunluđunu 3 katına  ıkararak 63x63 boyutlarında yamalar kullandıđımız  nerimizde, modelin kendi i erisindeki test i in ayrılan veriler  zerinde yapılan test sonucuna olumlu bir katkı sađlamadıđı g r lm řt r.

Modelin eđitimi sırasında kullanılan g r nt  yamalarının her birini kendi i erisindeki 64 bit piksel deđerlerini yine kendi histogramlarından yararlanarak 8 bite d n řt r rken kullanılan alternatif dođrusal normalizasyon y ntemlerinin elde edilen bařarım  zerinde belirgin etkileri olduđu g zlemlenmiřtir.  nerilen normalizasyon y ntemlerinden Picewise-Linear1 y ntemi modelin kendi i erisindeki testi i in ayrılan veriler  zerinde Linear y ntemine g re daha bařarısız olurken web tabanlı test uygulamasında Patient1 isimli hastanın 29. kesitinde daha bařarılı sonu lar vermiřtir.

 nerilen Piecewise-Linear2 y ntemi, modelin kendi i erisindeki testi i in ayrılan veriler  zerinde ve web tabanlı test uygulamasında Patient20 isimli hastanın 40. kesiti i in Picewise-Linear1 y ntemine g re daha iyi sonu lar verirken Patient1 isimli hastanın 29. kesiti i in daha k t  sonu lar vermiřtir.

Modelin eđitiminde kullanılan 18 hastadan birinde deđiřikliđe gidilmesinin modelin kendi i erisindeki testi i in ayrılan veriler  zerindeki bařarımda k   k bir etkisi olduđu, web tabanlı test uygulamasında Patient20 isimli hastanın 40. kesiti  zerindeki bařarımda kayda deđer bir fark yaratmadıđı g zlemlenmiřtir.

Denemelerimizde yama boyutu olarak 21x21 piksel kullandık. Yama boyutunu değiştirdiğimiz önerimizde 17x17 piksel boyutlarında görüntü yaması kullanmanın başarıma etkisini ölçtük. Yama boyutunu düşürdüğümüzde modelin kendi içerisindeki testi için ayrılan veriler üzerinde ve web tabanlı test uygulamasında denediğimiz MR kesitlerinde başarımın düştüğü gözlemlenmiştir.

Her görüntü yamasını kendi içerisindeki piksel değerlerini kullanarak normalize ettiğimiz önerimizi geliştirmek için tüm kesitlerdeki KR piksel değerlerinden elde ettiğimiz histogramdaki uç değerleri kullanarak yine her yamayı kendi içerisinde normalize ettiğimiz Treshold1 normalizasyon önerimizde modelin kendi içerisindeki testi için ayrılan veriler üzerinde başarımın arttığı, web tabanlı test uygulamasında Patient20 isimli hastanın 40. kesiti için başarımın daha iyi olduğu fakat Patient1 isimli hastanın 29. kesiti için başarımın oldukça düştüğü görülmüştür.

Yama boyutu 17x17 piksel olduğu durumda veri setindeki sınıfların temsil oranını 1/2 yerine 1/1 olacak şekilde değiştirdiğimiz önerimizde değişikliğin modelin kendi içerisindeki testi için ayrılan veriler üzerinde yapılan test sonucunda kayda değer bir etki yapmadığı, web tabanlı test uygulamasında değerlendirilen MR kesitlerinde daha kötü sonuçlar verdiği görülmüştür.

Yama boyutu 17x17 piksel ve sınıfların temsil oranını 1/2 olduğu durumda normalizasyon yöntemi olarak Piecewise-Linear1 yerine Treshold1 kullandığımız önerimizde değişikliğin modelin kendi içerisindeki testi için ayrılan veriler üzerinde

yapılan test sonucunda başarıma kayda değer bir katkı yaptığı, web tabanlı test uygulamasında değerlendirilen MR kesitlerin çıktılarında da başarıyı artırdığı görülmüştür.

Yama boyutu 17x17 piksel ve sınıfların temsil oranını 1/2 olduğu durumda normalizasyon yöntemi olarak Piecewise-Linear1 yerine Treshold1 kullandığımız önerimizde değişikliğin modelin kendi içerisindeki test için ayrılan veriler üzerinde yapılan test sonucunda başarıma kayda değer bir katkı yaptığı, web tabanlı test uygulamasında değerlendirilen MR kesitlerin çıktılarında da başarıyı artırdığı görülmüştür.

Önerdiğimiz Treshold1 normalizasyon yönteminde büyük bir 64 bit piksel değer aralığını 8 bit değer aralığına haritalamıştık. Ancak bu durumun hassasiyetin düşük olmasına neden olmasından dolayı kullandığımız histogramın tepe noktalarını baz alan 2 ve 3 parçalı normalizasyon yöntemlerini önerdik. Modelin kendi içerisindeki test için ayrılan veriler üzerinde yapılan test sonucunda 2 ve 3 parçalı normalizasyon daha önceki önerilen yöntemlere göre daha yüksek başarımlar sağlamanın yanında 3 parçalı normalizasyon en başarılı sonucu verdi. Web tabanlı test uygulamasında değerlendirilen MR kesitlerin çıktılarına bakıldığında ise daha önce önerilen yöntemlerin gerisinde kaldığı görülmüştür.

Doğrusal normalizasyon yöntemlerine alternatif olarak doğrusal olmayan Sigmoid normalizasyon yöntemi önerdik. Sigmoid yöntemi modelin kendi içerisindeki test için ayrılan veriler üzerinde yapılan test sonucunda 2 ve 3 parçalı normalizasyon

seviyesinde başarımları sağladı ancak web tabanlı test uygulamasında değerlendirilen MR kesitlerin çıktıları üzerinde daha başarılı sonuçlar verdi.

Şimdiye kadar önerdiğimiz tüm yöntemlerde normalizasyon görüntü yamasının içerisindeki piksel değerleri kullanılarak yapıldı ardından modele veriliyordu. Önerdiğimiz bu yöntemde ise veri setindeki MR kesitleri kendi içerisindeki piksel değerleri kullanılarak daha önce önerdiğimiz normalizasyon yöntemleri ile ayrı ayrı normalize edip saklanıyor. Her bir yöntem için model ayrı ayrı eğitilmek kaydıyla, normalize edilmiş bu kesitlerden alınan yamalar doğrudan eğitim için modele veriliyor ve başarımları sonuçları karşılaştırılıyor. Modelin kendi içerisindeki test için ayrılan veriler üzerinde yapılan testler sonucunda Piecewise-Linear2 yöntemiyle normalize edilmiş kesitlerden alınan görüntü yamalarının OpenCV kütüphanesinin resize fonksiyonu ile büyütüldüğü durumda en yüksek başarımlardan birini elde ediyor. Web tabanlı test uygulamasında değerlendirilen MR kesitlerin çıktılarına bakıldığında ise 2 farklı hastanın 2 farklı MR kesitinde şimdiye kadarki en iyi F1 skorlarını elde ediyor.

Tablo VI.1. Tm ikili denemelerin ađı eğitimi sırasındaki test accuracy ynnden karřılařtırmaları yanında, web tabanlı test uygulamasındaki cıktılarının F1 ve accuracy ynnden karřılařtırmaları.

| Alt Belim No | Durumlar (D1 / D2)                                                                             | D1 Test Acc. | D2 Test Acc. | Durum Deđiřim | D1 WTTU P1529 Acc. | D2 WTTU P1529 Acc. | D1 P1529 F1 | D2 P1529 F1 | D1 WTTU P20540 Acc. | D2 WTTU P20540 Acc. | D1 P20540 F1 | D2 P20540 F1 |
|--------------|------------------------------------------------------------------------------------------------|--------------|--------------|---------------|--------------------|--------------------|-------------|-------------|---------------------|---------------------|--------------|--------------|
| 5.1          | Veri Setinde 20 Hasta Olması / 18 Hasta Olması<br>Float64 Ten Ünit8 Dnřm / OpenCV Normalize | 0.790        | 0.801        | 0.011         |                    |                    |             |             |                     |                     |              |              |
| 5.2          | (20 hastanın kesitleri kullanıldı)<br>OpenCV Normalize / Gri Normalize                         | 0.790        | 0.845        | 0.055         |                    |                    |             |             |                     |                     |              |              |
| 5.3          | (18 hastanın kesitleri kullanıldı)<br>Veri Setindeki Test Miktarı %20 / %5                     | 0.849        | 0.855        | 0.006         |                    |                    |             |             |                     |                     |              |              |
| 5.4          | Devir Sayısı 20 / 30                                                                           | 0.865        | 0.875        | 0.010         |                    |                    |             |             |                     |                     |              |              |
| 5.5          | KR-Deđil Pikseller Arası Mesafe Yok / -3Px                                                     | 0.875        | 0.868        | -0.007        |                    |                    |             |             |                     |                     |              |              |
| 5.6          | Bytme iin Interpolation Yntemi AREA / LANCZOS4                                             | 0.865        | 0.866        | 0.001         |                    |                    |             |             |                     |                     |              |              |
| 5.7          | (20 devir yapıldı)                                                                             | 0.875        | 0.821        | -0.054        |                    |                    |             |             |                     |                     |              |              |
| 5.8          | Kullanılan Model VGG16 / ResNet50                                                              | 0.866        | 0.858        | -0.008        |                    |                    |             |             |                     |                     |              |              |
| 5.9          | Bytme iin OpenCV_INTERAREA / FatPixel<br>(Normalize iin Linear kullanıldı)                 | 0.858        | 0.826        | -0.032        |                    |                    |             |             |                     |                     |              |              |
| 5.10         | Bytme iin FatPixel kullanıldı                                                               | 0.826        | 0.830        | 0.004         |                    |                    |             |             |                     |                     |              |              |
| 5.11         | Bytme iin FatPixel / OpenCV_INTERAREA<br>(Normalize iin Prewise_Linear1 kullanıldı)        | 0.826        | 0.843        | 0.017         | 0.903              | 0.912              | 0.073       | 0.064       | 0.701               | 0.742               | 0.014        | 0.016        |
| 5.12         | (Bytme iin FatPixel kullanıldı)                                                             | 0.826        | 0.817        | -0.009        |                    |                    |             |             | 0.701               | 0.679               | 0.014        | 0.014        |
| 5.13         | Web Test Uyg. Hastalar P18P20 / P108P20                                                        | 0.795        | 0.826        | 0.031         | 0.903              | 0.948              | 0.073       | 0.040       | 0.718               | 0.701               | 0.013        | 0.014        |
| 5.14         | Yama Boyutu 17x17 / 21x21                                                                      | 0.826        | 0.850        | 0.024         |                    |                    |             |             | 0.701               | 0.776               | 0.014        | 0.025        |
| 5.15         | Normalizasyon Prewise_Linear1 / Threshold1                                                     | 0.802        | 0.795        | -0.007        | 0.795              | 0.900              | 0.034       | 0.061       | 0.610               | 0.718               | 0.012        | 0.013        |
| 5.16-1       | Veri Setinde KR/KR-Deđil Oranı 1 / 0.5                                                         | 0.795        | 0.835        | 0.040         | 0.900              | 0.942              | 0.061       | 0.062       | 0.718               | 0.743               | 0.013        | 0.018        |
| 5.16-2       | Normalizasyon Prewise_Linear1 / Threshold1                                                     | 0.865        | 0.872        | 0.007         | 0.860              | 0.863              | 0.039       | 0.047       | 0.884               | 0.877               | 0.010        | 0.010        |
| 5.17         | Normalizasyon Treshold 2 Para / 3 Para                                                       | 0.872        |              |               | 0.893              |                    | 0.062       |             | 0.794               |                     | 0.018        |              |
| 5.18         | Normalizasyon Sigmoid                                                                          | 0.866        | 0.852        | -0.014        | 0.843              | 0.876              | 0.065       | 0.069       |                     |                     |              |              |
| 5.19-1       | Yama ii Linear Norm. / Kesit ii Linear Norm.                                                 | 0.826        | 0.848        | 0.022         | 0.903              | 0.842              | 0.073       | 0.048       |                     |                     |              |              |
| 5.19-2       | Yama ii Prewise_Linear1 / Kesit ii Prewise_Linear1                                           | 0.843        | 0.867        | 0.024         | 0.912              | 0.910              | 0.064       | 0.111       | 0.742               | 0.782               | 0.016        | 0.020        |
| 5.19-3       | Yama ii Prewise_Linear2 / Kesit ii Prewise_Linear2                                           |              |              |               |                    |                    |             |             |                     |                     |              |              |

D1: Durum1  
D2: Durum2  
WTTU: Web Tabanlı Test Uygulaması  
P1529: Patient 1, Slice 29  
P20540: Patient 20, Slice 40  
Acc: Accuracy  
F1: F1-Score

## VII. SONUÇLAR

Beynin beyaz cevher olarak adlandırılan bölgesinde MR görüntülerinde yüksek yoğunluklu olarak görüntülenen lezyonların bilişsel hastalıklarla ilişkisini ortaya koyan bir çok çalışmanın varlığını göz önüne aldığımızda bu lezyonların beyinde ortaya çıkabileceği veya yayılabileceği alanları bilgisayar teknolojisini kullanarak öngörebilmek konuyla ilişkili tedavilerin geliştirilmesine katkı sağlayacaktır. Bu motivasyonla MS hastalarının iki farklı zaman diliminde çekilmiş ve ikinci zaman diliminde ortaya çıkmış yüksek yoğunluklu alanların KR olarak etiketlendiği MR görüntüleri ile çalıştık.

Bu görüntülere ön işlemler ile normalizasyon yöntemleri uygulayarak WMH ve Non-WMH olarak sınıflandırdığımız pikselleri merkezine alan görüntü yamalarını bu MR kesit görüntülerinden toplayıp problem için uygun olduğunu belirlediğimiz bir YSA'nın eğitimi için kullandık.

YSA modelinin başarımını yükseltebilmek ve bağımsız test için tasarladığımız web tabanlı test uygulamasında en iyi sonuçlara ulaşabilmek için veri seti üzerinde birtakım ön işlemler ve modelin hiper parametrelerinde değişiklikler içeren önerilerde bulunduk.

Çalışmamızı karşılaştırabileceğimiz benzer bir çalışma olmadığından sonuçları kendi önerdiğimiz yöntemler arasında karşılaştırdık. Modelin ve web tabanlı test uygulamasının çıktılarına baktığımızda özellikle normalizasyon temelli ön işlemlerin başarıma olumlu katkıları olduğunu gördük. MR kesiti içerisindeki piksel değerleri kullanılarak, Piecewise-Linear2 yöntemiyle normalize edilmiş görüntüler ile ağır

eđitimi yapıldığında; Eđitimi sırasında elde edilen başarımda ve web tabanlı test uygulamamızda elde edilen çıktılarda en iyi sonuçlara ulaşabildik.

Ancak ilk MR çekiminde uzman gözüyle bakıldığında herhangi bir oluşum görünmeyen bir beyin bölgesinde lezyon oluşacağını tahmin etmeye çalışmak problemin zorluđunu ortaya koymaktadır.

Bu çalışmada probleme uygun olduđunu düşündüğümüz bir veri seti üzerinde Derin Öğrenme yöntemleri kullanarak çözüm önerileri getirdik. İleriki çalışmalarda veri setinin miktar ve çeşitliliđini arttırarak, veri seti üzerindeki ön işlemlerde daha farklı yöntemler denenerek, son aşamada elde edilen çıktılarda kural tabanlı yöntemler kullanıp aykırı veriler temizlenerek ve uzman doktorlardan özellikle lezyon oluşma olasılıđı olan alanlara odaklanabilmek için destek alarak daha iyi sonuçlara ulaşılabilceđi kanaatindeyiz.

## KAYNAKLAR

- [1] Pim Moeskops, Jeroen de Bresser, Hugo J. Kuijf, Adriënne M. Mendrik, Geert Jan Biessels, Josien P.W. Pluim, Ivana Išgum, "Evaluation of a deep learning approach for the segmentation of brain tissues and white matter hyperintensities of presumed vascular origin in MRI", *NeuroImage: Clinical*, Volume 17, 2018, Pages 251-262, ISSN 2213-1582
- [2] Nalçakan, Yağız. (2019). "Derin Öğrenme İle Alzheimer Hastalığının Teşhisi."
- [3] Ali Arı, Davut Hanbay, "Bölgesel evrimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti", *Journal of the Faculty of Engineering and Architecture of Gazi University* 34:3 (2019) 1395-1408
- [4] Elene Iordanishvili, Melissa Schall, Ricardo Loução, Markus Zimmermann, Ketevan Kotetishvili, N. Jon Shah, Ana-Maria Oros-Peusquens, "Quantitative MRI of cerebral white matter hyperintensities: A new approach towards understanding the underlying pathology", *NeuroImage*, Volume 202, 2019, 116077, ISSN 1053-8119
- [5] Prins, N., Scheltens, P. "White matter hyperintensities, cognitive impairment and dementia: an update." *Nat Rev Neurol* 11, 157–165 (2015).
- [6] Ewoud J. van Dijk, Niels D. Prins, Henri A. Vrooman, Albert Hofman, Peter J. Koudstaal, and Monique M.B. Breteler, "Progression of Cerebral Small Vessel Disease in Relation to Risk Factors and Cognitive Consequences", *Stroke*. 2008;39:2712–2719
- [7] <https://nifti.nimh.nih.gov> (Mart 2021 tarihinde erişildi.)

- [8] Elliott, Colm and Belachew, Shibeshih and Wolinsky, Jerry S and Hauser, Stephen L and Kappos, Ludwig and Barkhof, Frederik and Bernasconi, Corrado and Fecker, Julian and Model, Fabian and Wei, Wei and Arnold, Douglas L, "Chronic white matter lesion activity predicts clinical progression in primary progressive multiple sclerosis", *Brain*, Volume 142, Issue 9, September 2019, Pages 2787–2799
- [9] Ç. R , "Multipl Sklerozda Fokal Lezyonların Difüzyon Ağırlıklı Manyetik Rezonans Görüntüleme ile Değerlendirilmesi", *Konuralp Medical Journal*, c. 2, sayı. 3, ss. 1-5, Ara. 2010
- [10] Gary A. Rosenberg, "Inflammation and White Matter Damage in Vascular Cognitive Impairment", *Stroke*. 2009;40:S20–S23
- [11] Wardlaw JM, Sandercock PA, Dennis MS, Starr J., "Is breakdown of the blood-brain barrier responsible for lacunar stroke, leukoaraiosis, and dementia?", *Stroke*. 2003 Mar;34(3):806-12. doi: 10.1161/01.STR.0000058480.77236.B3. Epub 2003 Feb 27. PMID: 12624314.
- [12] W.T. Longstreth, Teri A. Manolio, Alice Arnold, Gregory L. Burke, Nick Bryan, Charles A. Jungreis, Paul L. Enright, Daniel O'Leary, Linda Fried, "Clinical Correlates of White Matter Findings on Cranial Magnetic Resonance Imaging of 3301 Elderly People", *Stroke*. 1996;27:1274–1282
- [13] R. Şencan , "SWI MR Görüntüleme İle Hipertansif Arteryopati Tanısı Konulan Genç İnme Olgusu", *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, c. 7, sayı. 4, ss. 134-138, Ara. 2018
- [14] Hachinski VC, Potter P, Merskey H., "Leuko-araiosis.", *Arch Neurol*. 1987 Jan;44(1):21-3. doi: 10.1001/archneur.1987.00520130013009. PMID: 3800716.

- [15] Duygu Herek, Nevzat Karabulut, “Manyetik Rezonans Görüntüleme”, TTD Toraks Cerrahisi Bülteni, Cilt: 1, Sayı: 3, Eylül 2010, 214-222
- [16] Mehmet Barburoğlu, Serra Sencer, Kubilay Aydın, “Nöroradyolojik Görüntüleme ve Tedavi Yöntemleri”, <http://www.itfnoroloji.org/nororad/nororad.htm>
- [17] Aydoğdu, A. , Aydoğdu, Y. & Yakıncı, Z. D. (2017). “Temel Radyolojik İnceleme Yöntemlerini Tanıma.”, G.Ü. Sağlık Hizmetleri Meslek Yüksekokulu Dergisi, ISSN:2147-7892, Cilt 5, Sayı 2(2017), 44-53
- [18] Lesjak, Ž., Pernuš, F., Likar, B. et al., “Validation of White-Matter Lesion Change Detection Methods on a Novel Publicly Available MRI Image Database.”, Neuroinform 14, 403–420 (2016).
- [19] McCulloch, W.S., Pitts, W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics 5, 115–133 (1943).
- [20] Henry J. Kelley, “Gradient Theory of Optimal Flight Paths”, ARS Journal, 1960 30:10, 947-954
- [21] Ivakhnenko, A. G. and Lapa, V. G. (1965). Cybernetic Predicting Devices. CCM Information Corporation.
- [22] Fukushima, K., “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position.”, Biol. Cybernetics 36, 193–202 (1980).
- [23] Rumelhart, D., Hinton, G. & Williams, R., “Learning representations by back-propagating errors.”, Nature 323, 533–536 (1986).
- [24] Y. LeCun et al., "Backpropagation Applied to Handwritten Zip Code Recognition," in Neural Computation, vol. 1, no. 4, pp. 541-551, Dec. 1989, doi:

10.1162/neco.1989.1.4.541.

- [25] Sepp Hochreiter, Jürgen Schmidhuber; Long Short-Term Memory. *Neural Comput* 1997; 9 (8): 1735–1780.
- [26] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998
- [27] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio, “Generative Adversarial Nets”, *Proceedings of the International Conference on Neural Information Processing Systems (NIPS 2014)*. pp. 2672–2680
- [28] Karen Simonyan, Andrew Zisserman. "Very Deep Convolutional Networks for Large-Scale Image Recognition", *International Conference on Learning Representations*, 2015
- [29] [https://en.wikipedia.org/wiki/Flask\\_\(web\\_framework\)](https://en.wikipedia.org/wiki/Flask_(web_framework)) (Aralık 2021 tarihinde erişildi.)
- [30] Ian Goodfellow and Yoshua Bengio and Aaron Courville, *Deep Learning*, MIT Press, 2016
- [31] Li Deng and Dong Yu, *Deep Learning: Methods and Applications*, Now Publishers, 2014
- [32] Michael Xie, Neal Jean, Marshall Burke, David Lobell, and Stefano Ermon. 2016. Transfer learning from deep features for remote sensing and poverty mapping. In *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence (AAAI'16)*. AAAI Press, 3929–3935.
- [33] A. Arı and M. E. Berberler , "Yapay Sinir Ağları ile Tahmin ve Sınıflandırma

Problemlerinin Çözümü İçin Arayüz Tasarımı", Acta Infologica, vol. 1, no. 2, pp. 55-73, Dec. 2017

[34] <http://lit.fe.uni-lj.si> (Ocak 2020 tarihinde erişildi.)

[35] [https://tr.wikipedia.org/wiki/Sinir\\_h%C3%BCcresi](https://tr.wikipedia.org/wiki/Sinir_h%C3%BCcresi) (Aralık 2021 tarihinde erişildi.)

[36] <https://levelup.gitconnected.com/a-review-of-the-math-used-in-training-a-neural-network-9b9d5838f272> (Aralık 2021 tarihinde erişildi.)

