

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**DERİN SİNİR AĞLARI YÖNTEMLERİ KULLANILARAK
ALZHEİMER HASTALIĞININ MR GÖRÜNTÜLERİ ÜZERİNDE
OTOMATİK SINIFLANDIRILMASI**

Esra YÜZGEÇ

Yüksek Lisans Tezi

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

Yazılım Mühendisliği Bilim Dalı

TEMMUZ 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

**DERİN SİNİR AĞLARI YÖNTEMLERİ KULLANILARAK
ALZHEİMER HASTALIĞININ MR GÖRÜNTÜLERİ ÜZERİNDE
OTOMATİK SINIFLANDIRILMASI**

Tez Yazarı
Esra YÜZGEÇ

Danışman
Doç. Dr. Muhammed TALO

TEMMUZ 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yazılım Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Derin Sinir Ağları Yöntemleri Kullanılarak Alzheimer Hastalığının MR Görüntüleri Üzerinde Otomatik Sınıflandırılması
Yazarı:	Esra YÜZGEÇ
İlk Teslim Tarihi:	10.06.2023
Savunma Tarihi:	06.07.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Muhammed TALO Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Doç. Dr. Fatih ÖZYURT Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Ahmet Arif AYDIN İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza
Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Derin Sinir Ağları Yöntemleri Kullanılarak Alzheimer Hastalığının MR Görüntüleri Üzerinde Otomatik Sınıflandırılması” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

06.07.2023

Esra YÜZGEÇ



ÖNSÖZ

Alzheimer hastalığı tedavisi henüz mümkün olmayan dejeneratif bir hastalık türüdür. Son yıllarda Alzheimer hastalığının yaygınlığı giderek artmaktadır. Alzheimer, çok hafif bilişsel bozukluk (ÇHBB), hafif bilişsel bozukluk (HBB), orta seviye bilişsel bozukluk (OSBB) ve ileri seviye bilişsel bozukluk (İSBB) olmak üzere dört ana seviyeden oluşmaktadır. Hastalık, İleri Seviye Bilişsel Bozukluk aşamasına gelmeden kesin teşhis verilebilecek belirtiler göstermemektedir. Ancak bu belirtiler ortaya çıkmadan önce teşhisin gerçekleştirilebilmesi halinde hastanın yaşam kalitesini ve süresini uzatabilecek tedavi yöntemleri sağlanabilir. Bu amaçla bu tez çalışmasında Alzheimer hastalığı bulunmayan (Normal) bireylerin Manyetik Rezonans (MR) görüntülerinin yanında Alzheimer hastalığının Çok Hafif Bilişsel Bozukluk ve Hafif Bilişsel Bozukluk aşamasına sahip bireylerinde MR görüntüleri kullanılmıştır. Bu MR görüntüleri ile derin öğrenme yöntemleri kullanılarak erken aşama Alzheimer hastalığı sınıflandırılması gerçekleştirilmiştir.

Tez çalışması sürecinde her zaman yol gösterici olan, bilgi birikimi ile çalışmama farklı açılardan bakmamı sağlayarak katkıda bulunan değerli hocam ve tez danışmanım Doç. Dr. Muhammed TALO'ya sonsuz teşekkürü borç bilirim. Ayrıca, tüm hayatım boyunca yanımda olan, aldığım kararları her zaman destekleyen, tez çalışmam boyunca beni cesaretlendiren aileme teşekkürlerimi sunarım.

Esra YÜZGEÇ
ELAZIĞ, 2023

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vi
ABSTRACT	vii
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Alzheimer Hastalığı Teşhisine Yönelik Literatürde Gerçekleştirilen Çalışmalar	2
2. ALZHEİMER HASTALIĞI VE TEŞHİS YÖNTEMLERİ	6
2.1. Alzheimer Hastalığı	6
2.2. Alzheimer Hastalığı Teşhis Yöntemleri	9
2.2.1. Manyetik Rezonans Görüntüleme (MR)	10
2.2.2. Bilgisayarlı Tomografi (BT)	10
3. YAPAY ZEKÂ	11
3.1. Yapay Zekâ Alt Dalları.....	12
3.1.1. Uzman Sistemler	12
3.1.2. Genetik Algoritmalar.....	13
3.1.3. Bulanık Mantık.....	14
3.1.4. Makine Öğrenmesi	14
3.1.5. Yapay Sinir Ağları	16
3.1.6. Derin Öğrenme.....	18
4. MATERYAL VE METOT	23
4.1. Materyal.....	23
4.1.1. Veri Seti	23
4.2. Metot	25
4.2.1. Performans Ölçüm Yöntemleri	28
Karmaşıklık Matrisi (Confusion Matrix).....	28
4.2.2. Performans Değerlendirme Ölçütleri	29
5. BULGULAR VE TARTIŞMA	31
5.1. Normal-HBB Çalışma Grubu	32
5.2. Normal-ÇHBB Çalışma Grubu.....	36
5.3. HBB – ÇHBB Çalışma Grubu.....	40
6. SONUÇLAR.....	45
KAYNAKLAR.....	47
ÖZGEÇMİŞ	

ÖZET

Derin Sinir Ağları Yöntemleri Kullanılarak Alzheimer Hastalığının MR Görüntüleri Üzerinde Otomatik Sınıflandırılması

Esra YÜZGEÇ

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Yazılım Mühendisliği Anabilim Dalı

Temmuz 2023, Sayfa: xi + 52

Alzheimer hastalığı dejeneratif yani zamanla ilerleyen ve zihinsel işlev kaybına yol açan bir hastalık türüdür. Alzheimer hastalığı teşhis edilmesinin çok öncesinde oluşur ve ilerleme kaydeder. Hastalığın erken teşhis durumu oldukça zordur. Erken teşhis edilemediği için yıllarca ilerlemeyi sürdürür ve beyinde gerçekleşen temel hayati işlevlerin gerçekleştirilmesine engel olacak kadar ilerlemeye devam eder.

Alzheimer hastalığının dört ana aşamadan oluştuğu bilinmektedir. Bu aşamalar; ÇHBB, HBB, OSBB ve İSBB aşaması olarak tanımlanır. Erken aşamada ortaya çıkan belirtiler genellikle klinik olarak fark edilemeyecek kadar hafif belirtilerdir.

Alzheimer hastalığı klinik olarak hasta ve hasta yakınlarından, hastanın tıbbi ve travma geçmişi dinlenerek teşhis edilmeye çalışır. Bunun yanında hastanın beyin görüntüsü MR ve Bilgisayarlı Tomografi (BT) gibi bilgisayar destekli cihazlar aracılığı ile alınır. Alınan bu görüntüler üzerinden beyindeki değişiklikler gözlenerek hastalık teşhisine destek olması beklenir.

Bu çalışmada Alzheimer hastalığının erken aşamaları; üç ana çalışma grubu olarak ayrılmış ve bu çalışma grupları üzerinde ResNet-18, ResNet-50, ResNet101, DenseNet161, EfficientNet-B7, ConvNext mimarileri ile model eğitimleri gerçekleştirilmiştir. Normal- HBB aşamaları ele alınan çalışma grubunda en başarılı model olan ResNet-50 mimarisi; %95.40 doğruluk oranına ulaşmıştır. Normal-ÇHBB aşamalarından oluşan çalışma grubuna ait en başarılı model ise ConvNext mimarisi ile eğitilmiştir. Bu çalışma grubunda ConvNext modeli %97.53 başarı oranına ulaşmıştır. HBB-ÇHBB olmak üzere iki ana aşamadan oluşan üçüncü çalışma grubunda da en başarılı model ConvNext mimarisi ile eğitilerek %92.17 başarı oranına ulaşmıştır. Çalışma gruplarından elde edilen en başarılı modeller web ara yüzü ile entegre olarak test ortamına alınmıştır. Gerçekleştirilen çalışmanın Alzheimer hastalığının erken teşhisinde klinik testlere ve gerçek zamanlı olarak uygulanabilirliğe ışık tutacağı düşünülmektedir.

Anahtar Kelimeler: Alzheimer Hastalığı, Erken Teşhis, Derin Sinir Ağı, Manyetik Rezonans

ABSTRACT

Classification of Alzheimer's Disease on MR Using Deep Neural Network Methods

Esra YÜZGEÇ

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Software Engineering

July 2023, Pages: xi + 52

Alzheimer's disease is a degenerative disease that progresses over time and leads to loss of mental function. Alzheimer's disease develops and progresses long before it is diagnosed. Early diagnosis of the disease is very difficult. Since it cannot be diagnosed early, it continues to progress for years and continues to progress to the point that it prevents the basic vital functions of the brain from being performed.

Alzheimer's disease is known to consist of four main stages. These stages are defined as the ADHD, ADHD, OSHD and ISHD stages. Symptoms that occur in the early stages are usually too mild to be recognized clinically.

Alzheimer's disease is clinically diagnosed by listening to the patient's medical and trauma history from the patient and the patient's relatives. In addition, the patient's brain image is taken through computer-aided devices such as MRI and Computed Tomography (CT). Changes in the brain are observed through these images and are expected to support the diagnosis of the disease.

In this study, the early stages of Alzheimer's disease were divided into three main workgroups and model training was performed on these workgroups with ResNet-18, ResNet-50, ResNet101, DenseNet161, EfficientNet-B7, ConvNext architectures. The ResNet-50 architecture, which is the most successful model in the study group dealing with Normal-Mild Cognitive Impairment stages; reached an accuracy rate of 95.40%. The most successful model for the study group consisting of Normal-Mild Cognitive Impairment stages was trained with ConvNext architecture. In this study group, the ConvNext model achieved a success rate of 97.53%. In the third study group, which consists of two main stages, Mild Cognitive Impairment and Very Mild Cognitive Impairment, the most successful model was trained with ConvNext architecture and achieved a success rate of 92.17%. The most successful models obtained from the study groups were integrated with the web interface and put into the test environment. It is thought that the study will shed light on clinical tests and real-time applicability in the early diagnosis of Alzheimer's disease.

Keywords: Alzheimer's Disease, Early Diagnosis, Deep Neural Network, Magnetic Resonance

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Demans Çeşitleri	6
Şekil 2.2. Alzheimer hastalığı aşamaları	7
Şekil 2.3. Alzheimer hastalığı teşhisinde derin öğrenmenin rolü	9
Şekil 2.4. Sağlıkta bilgisayar destekli sistemlerin rolü	10
Şekil 3.1. Yapay zekanın alt dalları	12
Şekil 3.2. Uzman Sistemlerin işleyiş yapısı	13
Şekil 3.3. Genetik Algoritmalar işleyiş yapısı	14
Şekil 3.4. Bulanık Mantık işleyiş yapısı	14
Şekil 3.5. Makine öğrenmesi alt dalları temsili	15
Şekil 3.6. Doğal sinir hücresi	16
Şekil 3.7. Yapay sinir hücresi	16
Şekil 3.8. Yapay sinir ağı yapısı	17
Şekil 3.9. Yapay zekâ ve alt dalları şeması	19
Şekil 3.10. Geleneksel makine öğrenmesi yöntemi ve derin öğrenme	19
Şekil 3.11. Pikseller üzerinde gerçekleşen filtreleme işlemi	20
Şekil 3.12. Evrişimli sinir ağı temel katman yapısı	21
Şekil 3.13. Transfer öğrenme yapısı	22
Şekil 4.1. Sağlıklı beyin ve Alzheimer hastalığına sahip beyin görüntüsü	23
Şekil 4.2. Veri seti içeriği	24
Şekil 4.3. Kadın ve erkek hasta sayılarının dağılım grafiği	25
Şekil 4.4. Çalışma süreç tasarımı	26
Şekil 4.5. ResNet-50 mimarisinin katman yapısı	27
Şekil 4.6. ConvNext mimarisi katman yapısı	27
Şekil 4.7. EfficientNet mimarisi katman yapısı	28
Şekil 4.8. Karmaşıklık Matrisi	29
Şekil 5.1. Normal-HBB gurubu modellerinde doğrulama verilerinden elde edilen karmaşıklık matrisleri ..	34
Şekil 5.2. Normal-HBB gurubu modellerinde test verilerinden elde edilen karmaşıklık matrisleri	34
Şekil 5.3. Normal-HBB gurubu modellerinden elde edilen kayıp fonksiyonları	35
Şekil 5.4. Normal-HBB grubu ile eğitilen ResNet-50 modelinin web sayfası üzerinde örnek gösterimi	36
Şekil 5.5. Normal-ÇHBB gurubu modellerinde doğrulama verilerinden elde edilen karmaşıklık matrisleri ..	37
Şekil 5.6. Normal-ÇHBB gurubu modellerinde test verilerinden elde edilen karmaşıklık matrisleri	38

Şekil 5.7. Normal-ÇHBB gurubu modellerinden elde edilen kayıp fonksiyonları	39
Şekil 5.8. Normal-ÇHBB grubu ile eğitilen ConvNext modelinin web sayfası üzerinde örnek gösterimi...	40
Şekil 5.9. HBB-ÇHBB gurubu modellerinde doğrulama verilerinden elde edilen karmaşıklık matrisleri	41
Şekil 5.10. HBB-ÇHBB gurubu modellerinde test verilerinden elde edilen karmaşıklık matrisleri	42
Şekil 5.11. HBB-ÇHBB gurubu modellerinden elde edilen kayıp fonksiyonları	43
Şekil 5.12. HBB-ÇHBB grubu ile eğitilen ConvNext modelinin web sayfası üzerinde örnek gösterimi.....	44



TABLÖLAR LİSTESİ

	Sayfa
Tablo 5.1. Model eğitimlerinde kullanılan hiper parametre değerleri.....	31
Tablo 5.2. Çalışma gruplarından elde edilen doğrulama ve test başarı oranları.....	32
Tablo 5.3. Normal-HBB çalışma grubu veri sayıları	33
Tablo 5.4. Normal-HBB çalışma grubu için performans metrik sonuçları	33
Tablo 5.5. Normal-ÇHBB çalışma grubu veri sayıları.....	36
Tablo 5.6. Normal-ÇHBB çalışma grubu ile eğitilen modellerin hiper parametre değerleri	37
Tablo 5.7. Normal-ÇHBB çalışma grubu için performans metrik sonuçları.....	38
Tablo 5.8. HBB-ÇHBB çalışma grubu veri sayıları.....	40
Tablo 5.9. HBB-ÇHBB çalışma grubu için performans metrik sonuçları.....	42

SİMGELER VE KISALTMALAR

Kısaltmalar

YSA	: Yapay Sinir Ağı
HBB	: Hafif Bilişsel Bozukluk
ÇHBB	: Çok Hafif Bilişsel Bozukluk
OSBB	: Orta Seviye Bilişsel Bozukluk
İSBB	: İleri Seviye Bilişsel Bozukluk
MR	: Manyetik Rezonans
BT	: Bilgisayarlı Tomografi
ADI	: Alzheimer Disease International
LSTM	: Uzun Kısa Süreli Bellek (LSTM)
ADNI	: Alzheimer Hastalığı Nörogörüntüleme Girişimi
OASIS	: Açık Erişimli Görüntüleme Çalışmaları Serisi
Vit	: Görü Transformatörü

1. GİRİŞ

Alzheimer hastalığı, beyinde bilişsel tahribata yol açarak sürekli bir bilişsel yetenek bozulmasına sebep olan hastalıktır [1]. Dejeneratif yani zamanla ilerlemesini sürdüren bir hastalık türü olan Alzheimer süreç içerisinde zihinsel işlev kaybına yol açar. Erken teşhisi oldukça zor olan bu hastalık belirgin semptomlar ortaya çıkmadan öngörülemediği için yıllarca beyinde ilerlemeyi sürdürür.

Bu hastalığın durdurucu nitelikte bir tedavisi henüz bulunamamıştır. Durdurucu ve kesin bir tedavisi olmamasının yanında hastalığın oluşma ve ilerleme sebepleri de tam olarak bilinmemektedir. Kronik dejeneratif olan bu hastalığın başlangıç süresi de tam olarak tespit edilememektedir. İleri seviye semptomlar göstermeden teşhisi oldukça zor olan Alzheimer hastalığı; geçmişte yaşanan kafa travmalarına bağlı olarak gerçekleşiyor olabilir. Bunun yanında yüksek tansiyon, depresyon veya genetik aktarımlar sebebi ile oluştuğu tahmin edilmektedir [2]. 2021 Alzheimer Disease International (ADI) raporuna göre 1111 çok disiplinli klinisyen, 205 Bunama hastası ve 2122 Bunama hastası bakıcılarından oluşan bir anket gerçekleştirilmiştir. Bu ankete göre; yeterli eğitime sahip klinisyenlere erişim eksikliği sebebiyle %47, hastalığın teşhis ve tedavisinin maliyet oranı sebebi ile %34 ve Bunama tanısı koyulması endişesi ile %46 oranında bir kesim teşhis sürecinden kaçınmaktadır. Bu oranlar teşhisin önündeki önemli engeller olarak belirlenmiştir. Klinik teşhislerin önündeki engellerin diğer sebepleri ise özel teşhis testlerine erişimin kısıtlı olması (%38), hasta ve hasta yakınlarının Bunama tanısı koyulduktan sonra da hiçbir şey yapılamayacağı düşüncesinde olmasıdır (%33) [3].

Alzheimer teşhisinin klinik olarak zor olmasının yanında yukarıda bahsi geçen sebepler de dâhil edildiğinde erken teşhis oranının gittikçe zorlaştığı ve düştüğü öngörülmektedir. ADI'nin 2021 yılında yayınladığı Alzheimer raporuna göre dünyadaki Bunama hastalarının %75'i henüz tespit edilememiştir. Gelir seviyesi yüksek olmayan ülkelerde bu oranın %90 seviyelerinde olduğu tahmin edilmektedir [3].

Dünya üzerinde kayıtlı olarak teşhis edilmiş 55 milyon hasta bulunmaktadır. Bu sayının 2030 yılında 75 milyon seviyesine çıkması öngörülmektedir. 2020 yılından itibaren yaygınlaşan Covid-19 salgını sebebi ile dünyada insanların hastanelere ve sağlık hizmetlerine ulaşımı kesintiye uğradı. Bu durum göz önüne alındığında özellikle 2020 yılından sonra Bunama hastalığı belirtileri gösteren bireylerin de klinik testlere ve doktorlara ulaşımı kısıtlanmıştır. Bu sebeple teşhis ve tedavi süreçlerinin sekteye uğradığı tahmin edilmektedir [3].

ADI raporunda yayınlanan verilere ve araştırmalara göre ölüme sebebiyet veren %30 oranında yanlış teşhis bulunmaktaydı. Ancak bilgisayarlı görü taramaları ile yapılan yeniden değerlendirmelerde %25 oranında tanı düzeltilmesi gerçekleştirilmiştir. Bu durum göz önüne alındığında Bunama ve Alzheimer hastalığı teşhisi için klinik testlerin yanında, ilk aşama olarak

MR ve Bilgisayarlı Tomografi (BT) görüntüleri ile desteklenmesi olumlu sonuçlar doğurabilir [3].

Alzheimer hastalığının özellikle başlangıç ve orta seviye olarak tanımlanan aşamalarında beyin yapısı üzerinde gözle görülür değişim oranı oldukça düşüktür. Bu değişim büyük oranda gözle ayırt edilemeyecek seviyede olduğu için MR ve BT görüntüleri üzerinde klinik teşhis yapılması da zorlaşmaktadır. Bu aşamada hedeflenen, erken tanı sistemlerine katkıda bulunması adına hastalardan alınan MR ve BT görüntülerinin derin öğrenme modellerinde kullanılmasıdır. Bu çalışmada da erken teşhisin hayati olduğu Alzheimer hastalığının “HBB, ÇHBB ve Normal” sınıfları ile derin öğrenme modelleri eğitilmiştir. Eğitilen sınıfların Alzheimer hastalığının teşhisinin en güç olduğu aşamalar olması erken tanı ve etkili tedavi yöntemlerine destek olunabilmesi için önemlidir.

Derin öğrenme; son yıllarda sağlık sektöründe etkili olarak kullanılmaya ve faydalanılmaya başlanan bir yöntemdir [4]. Bu yöntem; Alzheimer hastalığının erken aşamaları için dünya çapında farklı hastalardan alınan görüntüler ile oluşturulmuş Alzheimer's Disease Neuroimaging Initiative (ADNI) ve Open Access Series of Imaging Studies (OASIS) veri setleri üzerinde de kullanılabilmektedir [5, 6].

Bu çalışmada OASIS veri setinden çeşitli niteliksel özellikler çıkarılarak, yalnızca Alzheimer faktörünün ele alındığı özel bir veri seti oluşturulmuştur. Oluşturulan veri setinde görüntüler her bir hasta için ayrılmış ve model eğitimlerinin hasta bazlı olarak gerçekleştirilmesi için veri düzenleme aşamasında özellikle dikkat edilmiştir. Bu sayede eğitilen modellerin daha önce karşılaşmadığı bir hasta üzerinde de yüksek başarı elde etmesi test edilebilir hale getirilmiştir.

Gerçek hasta verileri ile eğitilen modeller kullanılarak, uzman doktorların teşhis sürecine oldukça etkili bir biçimde yardımcı olunabileceği düşünülmektedir. Derin sinir ağlarının yüksek doğruluk oranı ile çalışması halinde uzman klinisyenlere ikinci bir bakış açısı desteği sunulması ve klinik testlere destek olunması beklenir.

1.1. Alzheimer Hastalığı Teşhisine Yönelik Literatürde Gerçekleştirilen Çalışmalar

Alzheimer hastalığının derin öğrenme yöntemleri ile sınıflandırılması üzerine literatür incelendiğinde, OASIS veri seti kullanılarak yapılan çalışmalar mevcuttur. OASIS veri seti literatürde en çok kullanılan veri setlerindendir. Literatürde OASIS veri seti ve diğer veri setlerinin birlikte kullanıldığı çalışmalar da mevcuttur. Bu çalışmalardan biri; 2022 yılında Andrea ve arkadaşları tarafından gerçekleştirilmiş bir çalışmadır [7]. Bu çalışmada ADNI, ADNI-2, OASIS ve Kaggle platformundan toplanan veri setleri olmak üzere toplamda 4 adet veri seti kullanılmıştır. Farklı veri setleri üzerinden farklı sayıda sınıflar kullanılarak model eğitimi

gerçekleştirmişlerdir. Çoklu sınıf durumlarında önerilen mimari kullanılarak %98.67 oranında doğruluğa ulaşmışlardır. İncelenen bu çalışmada toplam 416 hastadan oluşan OASIS verisi ve Kaggle Platformu üzerinden elde edilen veri seti ile 5121 MR görüntüsü kullanılmıştır.

İncelenen yayınlardan bir başkası ise 2019 yılında yayınlanan M. Raza ve arkadaşlarının yayınladığı uluslararası bir çalışmaya aittir [8]. Bu çalışmada OASIS ve ADNI veri setleri kullanılarak bir sınıflandırma işlemi gerçekleştirilmiştir. Yapılan çalışmada %95'in üzerinde bir sınıflandırma doğruluğu elde edildiği belirtilmiştir.

Alejandro Puente-Castro ve arkadaşları; 2020 yılında yayınladığı bir çalışmada ise ADNI ve OASIS veri setleri üzerinden alınan Sagittal MR görüntüleri kullanmışlardır [9]. Bu çalışmada kullanılan derin öğrenme modelleri hastaların yaş ve cinsiyet faktörlerini de göz önünde bulundurarak ve bu özelliklerden arındırarak ayrı ayrı eğitimler gerçekleştirmiştir. Bu eğitimler sonucunda OASIS veri seti ile %86.81 oranında, ADNI veri seti kullanıldığında ise %78.64 oranında bir ortalama doğruluk oranına ulaşmışlardır.

F. Previtali ve arkadaşları; 2017 yılında gerçekleştirdikleri çalışmada ADNI ve OASIS veri setlerini birlikte kullanarak sınıflandırma modelleri gerçekleştirmişlerdir [10]. Bu çalışma içerisinde ADNI veri setinde toplam 400, OASIS veri setinde ise toplam 150 hastadan alınan görüntüler kullanılmıştır. Bu çalışma sonucunda çok sınıflı modellerden ADNI veri setinde %99 oranlarında başarı söz konusu olurken, OASIS veri setinde %77 oranında bir sınıflandırma doğruluğu elde edildiği belirtilmiştir.

2020 yılında Ekin Yagis ve arkadaşları tarafından yayınlanan bir çalışmada; ADNI ve OASIS veri setleri kullanılarak sınıflandırma modeli oluşturmuşlardır [11]. Önerilen model üzerinde yapılan çalışmada ADNI ve OASIS veri setlerinden eşit sayılarda elde edilen toplam 400 hasta verisi kullanılmıştır. Bu çalışma üzerinde gerçekleştirilen modelde; ADNI veri seti için %73.4 sınıflandırma başarısına ulaşılırken OASIS için ise %69.9 oranında sınıflandırma başarısına ulaşmışlardır.

Ebrahimi-Ghahnavieh ve arkadaşları 2019 yılında gerçekleştirdikleri çalışmada 3 boyutlu olan MR görüntülerini 2 boyuta indirgeyerek 2 Boyutlu (2B) bir evrişimli sinir ağı modeli eğitmişlerdir. Çalışma içerisinde öncelikle GoogleNet, AlexNet, VGGNet-16, VGGNet-19, SqueezeNet, ResNet18, ResNet50, ResNet101 ve Inceptionv3 mimarileri kullanılarak model eğitimleri gerçekleştirilmiştir. Bunun yanında ayrıca farklı CNN modellerine Uzun Kısa Süreli Bellek (LSTM) ağları eklenerek yeni model başarıları elde edilmiştir. Bu çalışmada elde edilen sonuçlara göre LSTM ağı ile desteklenen evrişimli sinir ağlarında daha yüksek doğruluk oranlarına ulaşılmıştır [12].

Liu ve arkadaşları ADNI veri setinden elde edilen 710 hastanın MR görüntüleri üzerinde bir derin öğrenme çalışması gerçekleştirmişlerdir. Yayınlanan bu çalışmada 200 adet AD, 120 adet ilerleyici MCI, 160 adet ilerleyici olmayan MCI hastasının MR görüntüsü kullanılmıştır.

Sınıflar kendi aralarında ikerli olarak deęerlendirilmiř ve AD-CN, AD-MCI, CN-MCI, ve İlerleyici MCI / İlerleyici olmayan MCI olmak üzere eęitimler gerekleřtirilmiřtir. alıřmada bir zgn model eęitimi gerekleřtirilmiřtir. nerilen modelin en yksek doęruluk oranı AD-CN sınıfları arasında gerekleřmiř olup %94.65 olarak elde edilmiřtir. Sonu olarak ADNI veri setinden alınan grntler ile gerekleřtirilen alıřmaların umut verici olduęu belirtilmiřtir [13].

Farooq ve arkadaşları MR grntleri kullanarak Alzheimer hastalığının ve ařamalarının teřhisi iin bir derin sinir aęı alıřması gerekleřtirmiřlerdir [14]. Hastalığın ařamaları AD, MCI ve LCMI (Ge Hafif Biliřsel Bozukluk) olmak zere ADNI veri setinden elde edilen  sınıf olarak belirlenmiřtir. Evriřimli sinir aęlarından GoogleNet ve ResNet-18 ve ResNet-152 modellerini kullanarak yapılan alıřmada en bařarılı model %98.14 doęruluk oranı ile ResNet-152 olarak belirlenmiřtir.

Fuladi ve arkadaşlarının yayınladıęı alıřmada, derin sinir aęlarının Alzheimer hastalığı zerinde kullanımı hakkında bir inceleme gerekleřtirilmiřtir [15]. Yayınlanan alıřmaya gre Alzheimer hastalığının bilgisayar destekli sistemlerin kullanımı ile teřhisi ve sınıflandırılması bařlıklı alıřmaların son yıllarda yoęunluk gsterdięi belirtilmiřtir. Bu alıřmalar ierisinde sınıflandırma iřlemi iin en ok kullanılan veri setinin ADNI ve ikinci olarak OSIS veri setleri olduęu sylenmektedir. Bunun yanında veri tr olarak en ok kullanılan grntnn MR grntlerinden oluřtuęu belirtilmiřtir. Henz tedavisi bulunmayan Alzheimer hastalığı zerine yayınlanan bilgisayar destekli sınıflandırmaya destek olması hedeflenen alıřma sayısı giderek artmaktadır.

Sisodia ve arkadaşlarının 2023 yılında yayınladıkları makalede; Alzheimer hastalığı beyin ve hafıza fonksiyonlarını yok eden geri dnřmsz, ilerleyici bir nrodejeneratif hastalık olarak tanımlanmıřtır [16]. Alzheimer hastalığında beyin klmeye bařlar ve zamanla bunamaya dnřr. Erken teřhise destek saęlanması hedefine hizmet eden MR grntleri kullanılarak ok Hafif Biliřsel Bozukluk, Ge Hafif Biliřsel Bozukluk, Hafif Biliřsel Bozukluk ve Saęlıklı sınıfları arasında model eęitimleri gerekleřtirilmiř. Resnet-50, Xception, VGG19 DenseNet201 ve EfficientnetB7 modelleri kullanılmıř ve en yksek doęrulama bařarısını %96.59 ile DenseNet201 modeli saęlamıřtır.

Shangran Qiu ve arkadaşlarının ADNI study, AIBL, Framingham Heart Study ve National Alzheimer's veri setleri iin sırasıyla %99, %97, %87 ve %95 oranlarında model performansına ulařmıřlardı [17].

Farheen Ramzan ve arkadaşları gerekleřtirdikleri alıřmada derin ęrenme teknikleri kullanmıřlardır. İnce ayarlı transfer ęrenme modelleri kullanan Farheen Ramzan ve arkadaşları, modelden sırasıyla %97,92 ve %97,88'lik bir ortalama doęruluk oranı elde etmiřlerdir [18].

P. R. Buvaneswari ve arkadaşları 2021 yılında yaptıkları alıřmada ADNI veri setinden faydalanmıřlardır. Bu veri seti zerinden elde edilen AD, CN ve MCI sınıfları zerinde Resnet-


101 mimarisi ile bir çalışma gerçekleřtirmişlerdir. Bu çalışma sonucunda üçlü sınıflandırma üzerinde %96 doğruluk oranına ulaşmışlardır [19].

Bu tez çalışmasında da Alzheimer hastalığının erken teşhisine yönelik ikili sınıflandırıcılar geliştirilmiştir. Çalışma içerisinde Alzheimer hastalığı hakkında ayrıntılı bilgi verilmiş olup “Alzheimer Hastalığı ve Teşhis Yöntemleri” başlığı altında incelenmiştir. Gelişen bilgisayarlı sistemler ve bu sistemlerin sağlık alanında kullanımının açıklanması hedeflenmiş ve “Yapay Zeka” başlığı altında günümüzde kullanılan yapay zeka teknikleri hakkında bilgiler sunulmuştur. Çalışmada kullanılan veri seti ve derin öğrenme yöntemleri “Materyal ve Metot” kısmında irdelenerek ayrıntılı bilgi sunulması hedeflenmiştir. Gerçekleştirilen deneylerde elde edilen bulgular “Bulgular ve Tartışma” bölümünde sunularak tartışılmıştır. Bulguların sonuçlandırılması ise “Sonuçlar” başlığı altında gerçekleştirilmiş olup deney sonuçları yine bu başlık altında yorumlanmıştır.

2. ALZHEİMER HASTALIĞI VE TEŞHİS YÖNTEMLERİ

2.1. Alzheimer Hastalığı

Demans, zihinsel işlevlerin çeşitli nedenlerle zayıfladığı veya kayba uğradığı bir hastalık türüdür [20]. Küresel olarak uzayan yaşam süresini takiben Demans hastalığına sahip birey sayısının da artması beklenmektedir. Demans hastalıklarının Şekil 2.1’de gösterildiği gibi Parkinson, Vasküler Bunama gibi birçok çeşidi bulunmaktadır. Bu Demans türlerinden en yaygın olanı ise Alzheimer hastalığıdır.



Şekil 2.1. Demans Çeşitleri [21]

Alzheimer hastalığı nörodejeneratif olarak tanımlanan yani zamanla ilerleyen ve zihnin temel ve hayati işlevlerinde hasara yol açan bir Bunama türüdür [22]. Alzheimer hastalığı; bireyin zamanla temel fonksiyonlarını kaybetmesine yol açabilen ve sonucu büyük oranda ölüm olan bir hastalıktır. Bu hastalık çoğunlukta 65 yaş üzeri bireylerde ortaya çıkar ve bazı kaynaklarda yaşlılık hastalığı olarak belirtilir [23]. Sebepleri henüz belirlenememiş olsa da temel olarak beyinde işlevler arası iletişimi sağlayan sinir hücrelerinin (nöronların) tahribata uğraması ile oluştuğu söylenmektedir.

Alzheimer hastalığı, beyinde bulunan sinir hücrelerinde meydana gelen dejenerasyon probleminin dışında, beyinde anormal bir şekilde biriken proteinlerin sebep olduğu tahribata bağlı olarak da gerçekleşebilmektedir. Beyinde biriken ve sinirler arası iletişime engel olduğu düşünülen bu proteinler tau ve beta-amyloid olarak adlandırılmaktadır [24]. Tau proteini formu bozulmuş olarak nöronların içinde beta-amyloid proteini ise nöronların dışında birikerek tahribata uğrattırır. Bu anormal protein birikmesi ile tau, nöronlar içerisindeki besin aktarımını engeller. Beta-amyloid proteini ise nöronlar arası etkileşime sebep olarak hafıza ve yetenek bozukluklarına yol açmaya başlar. Bütün bu durumlar sonucunda nöronlarda hasar oluşumu ve bir yıkım söz konusu olur [25].

Alzheimer hastalığı belirgin semptomlar göstermeden yıllar önce beyinde biyolojik olarak oluşmaya ve belirginleşmeye başlar. Nörodejeneratif yani zamanla ilerlemeye bağlı bir hastalık olan Alzheimer'ın, ilk semptomlar ortaya çıkmadan 20 yıl öncesinde gelişmeye başladığı tahmin edilmektedir [26]. Bu durumlara bakıldığında yaşlılığa bağlı hastalık olarak tabir ediliyor olsa da Alzheimer hastalığının çok daha erken başladığı söylenebilir. Hastalık temel olarak beş ana aşamadan oluşmaktadır. Bu aşamalar Şekil 2.2'de gösterildiği gibi kontrol-normal, çok hafif bilişsel bozukluk, hafif bilişsel bozukluk, orta bilişsel bozukluk ve ileri bilişsel bozukluk olarak nitelendirilmektedir.



Şekil 2.2. Alzheimer hastalığı aşamaları [27]

Kontrol-normal olarak adlandırılan ilk aşamada hastanın günlük hayatında fark edebileceği herhangi bir semptom bulunmaz. Hafif semptomların henüz ortaya çıkmadığı ancak beyinde biyolojik olarak hastalık belirtilerinin bulunduğu aşama olarak nitelendirilebilir [27]. Bu aşamada beyinde hastalık ilerlemeye başlamıştır ancak hastanın günlük hayatını etkileyecek semptomlar bulunmamaktadır.

Çok hafif bilişsel bozukluk aşaması ise kontrol-normal grubu hastalara oranla daha ileri seviyede bir biyolojik yıkım mevcuttur. Bu yıkım ile ortaya çıkan semptomlar hastanın günlük hayatına etki edecek kadar belirgin semptomlar değildir. Ancak hastanın ailesi ve yakın çevresi tarafından fark edilebilecek hafif hafıza bozuklukları olarak görülür. Hafif bilişsel bozukluğa sahip hastaların %15'inde bunama gerçekleşirken yaklaşık 1/3'lük kısmında Alzheimer'a bağlı demans gelişimi görülür [28].

Hafif bilişsel bozukluk aşamasında bireyler hala çok belirgin ve hayati işlevlere engel olan bir belirtiler yaşamaya başlamış olmazlar. Bu aşamada genellikle fatura ödeme, market alışverişi veya buna benzer günlük ihtiyaçlarını karşılama süresinde uzama gibi belirtiler gösterirler [29]. Ancak hala günlük aktivitelerini yerine getirebilir ve yaşamlarını tek başlarına idame ettirebilir bir haldedirler.

Orta seviye bilişsel bozukluk Alzheimer'ın en uzun sürece sahip olan aşaması olarak nitelendirilir. Bu aşamada günlük hayata ve temel ihtiyaçlara dair aksaklıklar daha belirgin hale gelmiştir. Bireylerin kısa süreli hafıza ve konuşma gibi temel fonksiyonlarında aksaklıklar gelişmeye başlamıştır [30]. Bunun yanında günlük hayatta yemek yapmak, duş almak veya marketten alışveriş yapmak gibi birden fazla aşamaya sahip işlemleri yapmakta zorlanır ve karışıklık yaşamaya başlarlar. İlerleyen zamanla birlikte duygu durum bozuklukları ortaya

çıkmağa başlar ve hayati temel işlevler giderek zayıflar. Bu aşamada genellikle bir bakıcı veya aile bireyinden destek alma zorunluluğu doğmağa başlar.

İleri seviyeye gelen Alzheimer hastalığında bireyler tuvalete çıkma, konuşma, yemek yeme ve yutkunma gibi temel fonksiyonlarını büyük oranda kaybetmiş olurlar. Bu aşamada bir Alzheimer hastası genellikle tam zamanlı bir bakıcıya ihtiyaç duyar [31]. Beyinde sinirler arası iletişimi sağlayan nöronlar giderek daha fazla yıkıma uğrayacağı için yürüme ve yutkunma gibi işlevlerin kaybolması da kaçınılmaz hale gelir. Hareket kısıtlılığına yol açacak beyin bölgelerinde meydana gelen tahribat ile hasta yatağa bağımlı hale gelir ve fiziksel olarak daha da güçsüzleşir. Yutkunma işlevini tetikleyecek nöronlar da zamanla yok olur ve yutkunma işlevi de birey için giderek zorlaşır. Yutkunma işlevinin zorlaşması ve yerine getirilememesi sebebi ile yiyeceklerin sık sık nefes borusuna kaçması ve akciğerlere gıda partiküllerinin birikmesi ile enfeksiyon riski oluşur. Alzheimer hastalarının bu gibi işlevleri yerine getirememesi sonucu çeşitli fiziksel komplikasyonlar meydana gelir ve büyük oranda ölüm ile sonuçlanır [32].

Alzheimer hastalığının klinik olarak teşhis edilmesinde gecikmelere sebep olan en büyük etkenler olarak; dünya çapında yeterli uzman bulunmaması, kan ölçümleri için gerekli teçhizatın yetersiz kalabiliyor olması ve hastaların Alzheimer veya Demans hastası olarak tanımlanmaktan çekinmesi olarak sıralanabilir [33]. Alzheimer hastalığının tedavisi olmaması özellikle hastalık belirtilerine sahip hastaların teşhisten kaçmasına sebep olabilmektedir. Bunun yanında 2020 yılından itibaren global olarak yaşanan pandemi süreci Alzheimer hastalığının teşhisinde aksaklıklar meydana getirmiştir. Uzman Klinisyenlere ulaşma zorluğu artmış ve teşhis için gerekli testlere ulaşmayı zorlaştırmıştır. Demans hastası bireylerin yalnızca %35'lik bir kısmı COVID-19 salgını süresince uzman hekim ile görüşebilme imkânı bulunduğunu belirtmiştir. Bu durumun yanı sıra uzman hekimlerin %75'i, yapılan değerlendirmelere göre dünya çapında yaşlı nüfus oranı arttıkça, Alzheimer ve Demans sahibi birey oranının da artacağını ve bunun büyük zorluklara yol açabileceğini belirtmişlerdir. Bu durumda hasta sayısına bağılı olarak uzman klinisyen ihtiyacı, bakıma muhtaç hasta sayısı, ekonomik getirileri gibi birçok olumsuzluğu beraberinde getirebilir [33].


2022 yılı itibarı ile dünya genelinde 55 milyon bunama hastası bulunmaktadır ve bu hastaların %61 oranında bir kesimi orta veya düşük gelirli ülkelerde bulunmaktadır [34]. Alzheimer hastalarının teşhis, tedavi ve bakım masrafları gibi birçok ekonomik etkisi bulunmaktadır ve bu durum yılda ortalama 1,3 trilyon dolar harcamaya yol açmaktadır. Klinik testlerdeki pahalılık bu sayının daha da artmasına sebep olurken kan testlerinin daha uygun maliyetli hale getirilmesi durumunda daha ekonomik ve ulaşılabilir teşhis/tedavi süreci söz konusu olabilir.

2.2. Alzheimer Hastalığı Teşhis Yöntemleri

Alzheimer hastalığı, teşhis ve tedavi açısından hastayı, hasta yakınlarını ve uzman hekimleri oldukça zorlayıcı bir hastalık türüdür. Alzheimer hastalığının henüz tem bir tedavisi bulunamamış olsa da teşhisi; uzman klinisyenlerin kandaki biyolojik belirteçlere ve laboratuvar ortamında incelenen hasta verilerine dayanarak gerçekleştirdiği yöntemlere dayanır [35]. Bu sebeple gibi klinik testlerin yanında radyolojik görüntüleme sistemleri de kullanılarak teşhis aşamasında destek bir fikir alınır.

Bütün bu teşhis çalışmalarına rağmen geçtiğimiz yıllarda yapılan bir çalışmaya göre klinik tanımlar ile alınan teşhis kararları radyolojik görüntüleme cihazlarından elde edilen veriler ile karşılaştırılmıştır. Bu karşılaştırma sonucunda teşhis ve hastalık ile uyuşmayan yanlış teşhisler olduğu ortaya çıkmıştır. Elde edilen sonuçlar, Alzheimer tanısı ile hayatını kaybetmiş hastalarda %30'a yakın bir oranda yanlış tanı ile karşılaşıldığını göstermekteydi [36]. Bu sebeple klinik testlerin yanında radyolojik görüntüleme cihazları da teşhis aşamasında oldukça büyük bir önem taşımaktadır.


Son yıllarda yapılan çalışmalar incelendiğinde Alzheimer hastalığının tanısı için ele alınan MR ve BT görüntüleri kullanılarak gerçekleştirilen derin öğrenme modelleri ile hastalık teşhisine destek olunması hedeflenmiştir [37, 38, 39]. Radyolojik görüntü üzerinden beyinde gerçekleşen küçük değişikliklerin erken aşamada göz ile teşhis edilmesi oldukça güçtür. Bu sebeple klinik karar sistemlerinin yanında Şekil 2.3'te gösterildiği gibi bilgisayar destekli sistemlerden faydalanılarak teşhislerin daha hızlı ve etkili yapılması için çalışmalar devam etmektedir.



Şekil 2.3. Alzheimer hastalığı teşhisinde derin öğrenmenin rolü [40]

2.2.1. Manyetik Rezonans Görüntüleme (MR)

Bilgisayar destekli görüntüleme cihazları sağlık alanında, teşhis aşamasında oldukça yoğun bir biçimde kullanılmaktadır. MR da klinik çözüm yolları için kullanılan görüntüleme tekniklerinden biridir [41]. Manyetik Rezonans Görüntüleme cihazları ile elde edilen görüntüler oldukça net olduğu için tıbbi açıdan oldukça kıymetlidir. MR görüntüleme teknikleri ile elde edilen görüntüler hastalıklar hakkında bilgi edinmede Şekil 2.4'te gösterildiği gibi oldukça öncü bir rol oynar. Bu aşamada MR görüntülemesinde bulunan temel amaç sinyal işleme, matematiksel problemler ve fizik kanunlarına tabi olarak geliştirilen elektriksel sistemin kullanılarak, sağlık alanında faydalı olmasını sağlamaktır.



Şekil 2.4. Sağlıkta bilgisayar destekli sistemlerin rolü [42]

2.2.2. Bilgisayarlı Tomografi (BT)

Günümüzde sağlık alanında hastalık teşhisleri için oldukça önemli bir yer teşkil eden BT cihazları 1960'lı yıllarda bilgisayar teknolojilerinin geliştirilmeye ve uygulanmaya başladığı dönemde ortaya çıkmıştır [43]. İcat edildiği dönemde sağlık alanında kullanılıyor olmasa da zamanla tıp bilimi için oldukça önemli bir yer edinmiştir. BT görüntülemesi için gerçekleşen ilk başarılı deneme 1972 yılında Tomografi cihazının mucidi olarak anılan Hounsfield tarafından gerçekleştirilmiştir [44]. BT yöntemi diğer bilgisayar destekli görüntüleme sistemlerine oranla daha yüksek çözünürlük sağlamaktadır. Bu sayede kemik ve kas dokularındaki anormal değişimleri belirli bir dereceye kadar görüntüleyebilir ve bu görüntülerden görüş alınarak teşhis kolaylığı sağlanabilir durumdadır. Tıp alanında doktorların özellikle göz ile muayene ve kan testlerinin yanında görüntüleme cihazlarının oldukça önemli bir yeri olduğu belirtilebilir.

3. YAPAY ZEKÂ

İnsan beyninden ilham alınarak geliştirilmiş bir teknoloji olan yapay zekâ, herhangi bir canlının sahip olabileceği özellikleri kendinde bulundurmaya hedefleyen bir sistemdir [45]. İnsana özgü davranışlar geliştirme, düşünme, kavrama yetenekleri, yeni fikirler ve problemlere karşı yeni çözümler üretebilme gibi özellikler barındırması beklenir [46]. Bu sistemde; canlılarda var olan muhakeme yeteneğinin makinelere/bilgisayarlara yüklenmesi hedeflenmiştir.

İnsan zihni doğduğu andan itibaren karşılaştığı problemleri anlama, düşünme, yorumlayıp karara varabilme ve değerlendirmeler sunup sonuçlandırabilme gibi birçok özelliğe sahiptir. İnsan çevresini algılamaya başladığı andan itibaren gelişen olayları kaydeder ve bunları tecrübeler ile öğrenme ilkesine göre değerlendirerek zihninde saklar. Bu değerlendirmeler; daha önce karşılaşılmayan bir durum ile algılanır ve yeni bir çözüm yolu hızlıca ortaya atılabilir. Bu aşamada Yapay zekâ; insan beynini ve öğrenme yapısını taklit ederek daha önce karşılaşılmayan problemlere de hızlı çözümler üretebilmeyi hedefler.


İlk olarak Allon Mathison Turing tarafından ortaya atılan “Makineler düşünebilir mi?” sorusu ile kavramsal nitelik kazanmıştır [47]. Bu aşamada ortaya çıktığı yıllarda yapay zekanın temel problem çözme, matematiksel işlemleri rahatlıkla kavrayabilmesi gibi hedefler taşımaktaydı. Ancak zamanla insanı taklit eden ve üretim ve sanayi gibi konularda insan gibi düşünebilen, fikirler üretebilen ve insan gibi davranabilen bir sistem oluşturulması hedeflenmeye başlandı. Bununla birlikte Robotların da yapay zekâ ile desteklenerek insan hayatında kolaylık sağlaması hedefleri ortaya çıktı. Günümüzde yapay zekâ sağlık, savunma sanayi, üretim teknolojileri, lojistik ve ticaret gibi birçok alanda kullanılmaya başlanmıştır [48].

Günümüzde neredeyse her sistemin içerisinde bulunan yapay zekâ; insanın deneyimler ile öğrenmesinin bir modellemesi olarak ele alınabilmektedir. Modellen bu sistemler; bütünleştirildiği yapının insan gibi düşünebilmesini ve çözüm sunabilmesini sağlamayı amaçlar. Yapay zekâ üzerine çalışmalar günümüzde de devam etmektedir ancak henüz insan zekasının birçok işlevi bu modelleme yapılarının dışında kalmaktadır [49]. Yapay zekâ sistemleri ortaya çıktığı ilk yıllarda temelde bir makinenin öğrenmesini amaçlamaktaydı. Bu sayede makinelerin veya robotların insan hayatını kolaylaştıracağı düşünülmekteydi.

Yapay zekâ; güçlü ve zayıf olmak üzere iki ana başlık altında incelenebilmektedir [50]. Bunlardan ilki olan güçlü yapay zekâ, insana özgü yetenekleri kullanabilen bir sistem türüdür. Düşünme, sorma, problem çözme, interaktif bir şekilde iletişim kurabilme ve daha önce karşılaşmadığı sorunlara deneyimler ile sonuçlar üretebilme yeteneğine sahiptir. Zayıf yapay zekâ ise tam aksine yalnızca kendisine öğretilen komutları yerine getirir. Yapay zekanın temel prensibi, insan zihni gibi davranma yetisini kazanmak olsa da zayıf yapay zekanın

komutlandırılmış bir işi yapabilmekten öteye geçemediği görülür. Bu aşamada güçlü yapay zekâ; insan gibi hareket edecek şekilde tasarlanmış sistem olarak bildirilebilir. Ancak zayıf yapay zekâ makinenin sadece belirli bir işi yapabilmesini sağlayan bir program olarak tanımlanır.

Yapay zekâ ortaya çıktığı günden beri gelişim göstererek ilerleyen bir teknolojidir. Zamanla gelişerek farklı yönler ayrılana birden fazla daldan oluşmaktadır. Bu alanlar üzerinde geliştirildikleri veri türlerine göre, kullanım alanlarına göre, geliştirilme biçimlerine göre birçok türe ayrılmışlardır. Bu alanlar farklı alanlara hitap ediyor olsa dahi temelinde Şekil 3.1’de gösterildiği gibi yapay zekâ teknolojisi yatmaktadır.



Şekil 3.1. Yapay zekanın alt dalları [51]

Yapay zekâ birçok gelişmiş teknolojinin temelini oluşturmuş ve insan hayatında önemli etkilere yol açacak ve kolaylık sağlayacak alt dallara bölünmüştür. Yapay zekâ teknolojisinin temel alt dalları;

- Uzman Sistemler
- Genetik Algoritmalar
- Makine Öğrenmesi
- Bulanık Mantık
- Yapay Sinir Ağları

şeklinde sıralanabilir.


3.1. Yapay Zekâ Alt Dalları

3.1.1. Uzman Sistemler

Uzman sistemler temelde bir uzmanın sağlayabildiği bilgi ve çözümü sağlayabilmesi için geliştirilen sistemler olarak tanımlanabilmektedir. Uzman sistemler tek bir

alanda gelişen ve bir alanda uzmanlaşmış insanın işini yapabilmesi hedeflenen sistemler olarak tanımlanırlar [52].


Yapay zekâ alt dalı olarak tanımlanan uzman sistemler genel yapay zekâ anlayışından farklı olarak tek bir alanda uzmanlaşmayı hedef edinirler. Bu anlamda yapay zekadan temel anlamda ayrıldıkları söylenebilir [54]. Uzman sistemlerin oluşturulması iki ana adıma dayanır. Bunlardan ilki sisteme öğretilmesi hedeflenen bilgilerin alanında uzman kişilerden toplanarak bir veri kümesi haline getirilmesidir. İkinci adımda ise toplanan veriler sisteme öğretilir ve problem çözümleri için kullanılması hedeflenir. Uzman sistemlerin işleyişi Şekil 3.2’de gösterildiği gibi temsil edilebilir.



Şekil 3.2. Uzman Sistemlerin işleyiş yapısı [53]

3.1.2. Genetik Algoritmalar


Genetik algoritmalar, problem çözümü için optimum noktaya ulaşmayı hedefleyen algoritmalarlardır. İnsanların hayatta kalma ve evrim sürecini ilham alarak geliştirilen sistemler olarak tanımlanırlar [55]. İç içe gelişim gösteren adımlar ile tanımlanarak optimum çözüm noktasına ulaşmayı hedefleyen algoritmik adımlardan oluşurlar. Bu adımlar aracılığı ile önce gerçek hayat problemlerine uygun modeller geliştirilir ardından karşılaştıkları problemlere çözümler sunabilirler. İnsan gelişimi ve evrimini ilham alarak geliştirilmiş bu sistemde; bu düşünceyi destekler biçimde isimlendirilmiş popülasyon, çaprazlama, kromozom ve mutasyon adımları yer almaktadır. Şekil 3.3’te Genetik algoritmaların temel algoritmik yapısı görselleştirilmiştir.



Şekil 3.3. Genetik Algoritmalar işleyiş yapısı [55]

3.1.3. Bulanık Mantık

Bulanık mantık, insan zihnine yakın bir modelleme yaparak, karar alma ve değerlendirme süreçlerini yürütebilecek bir sistemin oluşturulmasını hedefler. Mantık; bilgisayar dilinde 0 ve 1 karakterlerinden oluşan ve net sonuçlar barındıra bir yapı olarak tanımlanmaktadır [56]. Bulanık mantık ise bu net kararların yanı sıra insan gibi ara değerler ile de karar verebilen ve yeni sonuçlar üretebilen bir sistemi hedefler. Bu sebeple bulanık mantık kavramı kesinlik değil bir yaklaşım biçimi içerir. Bulanık mantık sistemlerinin oluşturulması ve kullanılması aşamasında ele alınan dört ana başlık bulunmaktadır. Bu başlıklar; Şekil 3.4'te gösterildiği gibi bilgi tabanı, çıkarım motoru, bulandırma ve durulama olarak sıralanır.




Şekil 3.4. Bulanık Mantık işleyiş yapısı [57]

3.1.4. Makine Öğrenmesi

Makine öğrenmesi, bilgisayarlı sistemlerin belirli bir türdeki veriyi kullanarak işlemesini ve sonuçlandırmasını amaçlayan bir yapay zekâ alt dalıdır [58]. Makine öğrenmesi; yapay zekâ

ile aynı alt mantığa sahip olarak yani insanın öğrenme ve karar verme sürecinden esinlenilerek geliştirilen bir sistemdir. Makine öğrenmesinde Şekil 3.5'te gösterildiği gibi temel olarak denetimli ve denetimsiz olmak üzere iki tür yer almaktadır. Denetimli makine öğrenmesi etiketlenmiş sınıflar veya kesin değerler elde edilmiş veriler ile eğitilerek sonuç alınmasını sağlayan yapılardır [59]. Denetimsiz makine öğrenmesinde ise denetimli makine öğrenmesinin aksine girdi verilerinin net değerleri veya etiketleri bulunmaz. Denetimli makine öğrenmesi 0 veya 1 gibi net bir sonuca ulaşabilir ancak denetimsiz makine öğrenmesinde ara değerler ve tahmin sonuçları bulunmaktadır.



Şekil 3.5. Makine öğrenmesi alt dalları temsili [60]


Denetimli makine öğrenmesinde veriler ve alınması beklenen sonuçlar net olarak tanımlıdır. Bu sayede girdi verileri ile eğitilen sisteme bir test verisi yüklendiğinde hangi sonucu vermesi gerektiği de bilinir ve doğruluk testleri gerçekleştirilebilir.

Denetimli makine öğrenmesi modelleri Sınıflandırma ve Regresyon olmak üzere iki alt başlıktan oluşmaktadır [61]. Denetimsiz makine öğrenmesi problemlerinde girdi verilerinin etiketli veya tanımlı olmamasının yanında test verileri için de tanımlanan net değerler genellikle bulunmaz. Bu yönleri ile denetimsiz makine öğrenmesi yöntemleri sınıflandırma veya regresyon problemlerinden ayrılırlar.

Denetimsiz makine öğrenmesi; yöntemleri kümeleme, birliktelik kuralları ve boyut azaltma yöntemleri olmak üzere üç alt dala ayrılmaktadır. Elde edilmiş etiketsiz verilerin uzaklık veya benzerlik gibi değerlerin kullanımı ile analize tabi tutulması ve sonuçlandırılması işlemine kümeleme adı verilir [62]. Analiz yapılan veri setindeki değerler arasındaki bağlantının kurularak bir birliktelik sorgulaması yapılması ile gerçekleştirilen makine öğrenmesi tekniğine ise birliktelik kuralları denir. Birliktelik kuralları ile veri seti içerisindeki değerler kullanılarak analiz yapılması ve bir sonuç çıkarılması hedeflenir. Boyut azaltma işleminde ise veri seti içerisinde bulunan değerlerin belirli istatistiksel ve matematiksel kurallar uygulanarak kontrolü bir biçimde azaltılması hedeflenmektedir.


3.1.5. Yapay Sinir Ağları

Yapay sinir ağları (YSA) son yıllarda kullanımı giderek yaygınlaşan bir makine öğrenmesi alt dalıdır. Yapay sinir ağlarının çalışma prensibi, Şekil 3.6'da gösterildiği gibi insan beyninin çalışma ve nöronlar arası iletişim prensipleri ilham alınarak geliştirilmiştir.



Şekil 3.6. Doğal sinir hücresi [63]


YSA'lar; görüntü işleme, doğal dil işleme, ses tanıma ve sinyal işleme gibi oldukça farklı kullanım alanlarına sahiptir. YSA'lar, yapay nöronlar olarak adlandırılan matematiksel işlemlerden oluşturulmuş bir program tasarımıdır. Geliştirilen yapay nöronlar, Şekil 3.7'de gösterildiği gibi insan beynindeki gerçek nöronların işlevlerine benzer şekilde hareket ederler. Geliştirilen her bir yapay nöron girdi verilerini ele alır, işleme adımlarını gerçekleştirir ve sonuç çıktıların üretmesini sağlar. Elde edilen çıktılar bir sonraki nöronun girdi değeri olarak veya sonuç çıktısı olarak kullanılabilir.



Şekil 3.7. Yapay sinir hücresi [64]

YSA'lar, insan öğrenme sürecine benzer şekilde sebep ve sonuç ilişkisi ile öğrenme performanslarını artırmaktadır. Girdi verileri ve çıktı verileri arasındaki ilişkiyi öğrenerek ağ performansı artırılmaktadır [65]. Öğrenme işlemi elde edilen verilerin belirli bir kısmının YSA'ya etiketli bir biçimde verilmesi işe başlatılır. Ağ elde edilen verilerle belirli girdi ve çıktı değerleri üretir, bu değerlere bağlı olarak ağ parametreleri üzerinde değişiklikler gerçekleştirilir ve ağın performansı artırılır.

YSA yapıları temel üç katman üzerine kurulmaktadır. Bu katmanlar Şekil 3.8'de gösterildiği gibi yapılandırılmış olup; girdi katmanı, gizli katmanlar ve çıktı katmanı olarak adlandırılmaktadır. Girdi katmanında; ağda işlenecek veriler girdi olarak kabul edilir ve sinir ağına girişleri sağlanır. Gizli katmanlarda ise; ağa alınan girdi verileri işlenerek çıktı sonuçları hesaplanır ve çıktı katmanına iletilmesi sağlanır [66]. Son olarak sonuçların elde edildiği katman ise çıktı katmanıdır. YSA'lardaki temel farklılığı gizli katmanların sayısı ve boyutu gibi faktörler belirlemektedir. Bu katmanlar içerisindeki özellikler ağ performansı üzerinde büyük öneme sahiptir.



Şekil 3.8. Yapay sinir ağı yapısı [67]

YSA'lar temel üç katman yapısı içerisinde kullandıkları çeşitli hiper parametreler ile ağ performansını geliştirmeyi hedeflerler. Bu hiper parametrelerden biri olan aktivasyon fonksiyonu sinir ağı içerisindeki nöronlara alınan girdilerin işlenerek çıktı değerinin üretilmesini sağlayan matematiksel işlemlerdir. YSA'larda kullanılan en yaygın aktivasyon fonksiyonlarına sigmoid, ReLU ve Tanh fonksiyonları örnek verilebilmektedir [68].

YSA modellerinde eğitimleri denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki ayrı yöntem kullanılmaktadır. Denetimli öğrenme olarak adlandırılan yöntemde, YSA üzerinde kullanılacak eğitim verileri çıktıları da içeren bir veri kümesi olarak ele alınır. Denetimli öğrenme yönteminde, YSA çıktısının eğitim sonucunda elde ettiği çıktı ile gerçek çıktı verileri arasındaki ilişki geriye doğru yayılım adı verilen matematiksel bir teknik ile hesaplanır. Geriye doğru

yayımlı tekniği; ağ hiper parametrelerini optimize etmek ve ağ performansını artırmak için yardımcı bir araç olarak kullanılmaktadır [69].

Diğer bir YSA öğrenme tekniği olan denetimsiz öğrenmede ise, ağ üzerinde eğitilen veriler herhangi bir çıktı verisine sahip olmadan eğitime alınırlar [70]. Bu yöntemde girdi verileri analiz edilir ve benzer özelliklere sahip girdi verileri gruplandırılır. Bu gruplandırma yöntemi ile; veri kümesi üzerindeki farklı özellikler tanımlanır ve veri kümesinin daha iyi anlaşılması, YSA'nın iyi sonuçlar vermesi amaçlanır.


Yeni öğrenme teknikleri ve daha hızlı hesaplama teknolojileri ile birçok alanda kullanımı ve gelişimi devam eden YSA özellikle çok katmanlı sinir ağı teknolojisi olarak ortaya çıkan derin öğrenme yöntemleri ile çeşitli alanlarda gelişmelerini sürdürmektedir. Yapay sinir ağları derin öğrenme alanının gelişimi ile daha etkin olarak kullanılmaya başlanmıştır [71]. Özellikle ses, görüntü ve doğal dil işleme gibi karmaşık veriler üzerinde kullanımı yaygınlaşmaktadır.

Nesne tanıma yüz tanıma, video analizi, görüntü işleme gibi çeşitli uygulama türleri oldukça farklı alanlara yayılarak günlük hayata uyarlanmaya başlanmıştır, bu teknolojilerin sağlık alanında da kullanımı ön plana çıkmıştır. Derin öğrenme teknolojileri sağlık alanında MR ve BT görüntülerini girdi verisi olarak almaktadır [72]. Bu karmaşık görüntüler üzerinde; sınıflandırma ve bölütleme gibi teknikler kullanarak hastalık teşhislerine yardımcı olunması hedeflenmektedir. YSA teknolojilerinin sağlık gibi hayati önem taşıyan alanlarda efektif olarak kullanılabilmesi için çalışmalar ve araştırmalar devam etmektedir.

3.1.6. Derin Öğrenme


Derin öğrenme, insan beyninden ve öğreniminden ilham alınarak ortaya çıkarılmış bir yapay zekâ alt dalıdır. Programlama tarihine bakıldığında, gerçekleştirilecek her bir işlemin komutlar halinde yazıldığı görülür. Derin öğrenmede ise tıpkı insanların tecrübeler yoluyla öğrenmesine benzer olarak; deneyimlerle öğrenmesi söz konusudur. Diğer bir deyişle bilgisayara aktarılan veri dünyası, eğitilen model tarafından anlamlandırılır [73].

Yapay zekâ kavramı ortaya çıktıktan sonra makine öğrenmesi problemleri ele alınmaya başlanmış ve yapay zekâ teknolojisinin bir alt dalı olarak makine öğrenmesi kavramı ortaya çıkmıştır. Geleneksel makine öğrenmesi kavramının bir alt dalı olan derin öğrenme kavramı da ilk olarak 1980'lerde ortaya çıkmıştır. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki kavramsal ilişki Şekil 3.9'te gösterildiği gibidir.



Şekil 3.9. Yapay zekâ ve alt dalları şeması [74]

Makine öğrenmesi çalışmalarından sonra bir alt dal olarak ortaya çıkarılan derin öğrenmede yapay sinir ağlarında bulunan katmanlar artırılmış ve gizli katmanlar eklenerek yeni ve derin bir öğrenme yapısı oluşturulmuştur. Makine öğrenmesi yöntemleri ile gerçekleştirilen çalışmalarda komutlar ve özellik çıkarma işlemleri gerçekleştirilir ardından model eğitimi başlatılır. Derin öğrenme çalışmalarında ise özellik çıkarımı aşaması modele bırakılır. Şekil 3.10'da gösterildiği gibi makine öğrenmesi ve derin öğrenme çalışmaları arasındaki temel fark, kullanıcı eliyle ön işleme adımlarına ihtiyaç duyulmamasıdır.




Şekil 3.10. Geleneksel makine öğrenmesi yöntemi ve derin öğrenme [75]

Derin öğrenme, savunma ve güvenlik sanayisi, yüz ve ses tanıma, otonom araçlar gibi birçok alan ve teknolojide kullanıldığı gibi sağlık sektöründe de yaygın olarak kullanılır. Özellikle erken teşhisin önemli olduğu hastalıklar üzerine derin öğrenme ile çalışmalar gerçekleştirilmektedir [76]. Bu çalışmalar sonucunda elde edilen derin öğrenme modelleri; doktorlar tarafından yardımcı destek olarak kullanılır. Bu sayede ise tıbbi görüntülerin yorumlanması ve erken teşhis aşamasında önemli sonuçlar ortaya koyulabilir [77].

Sağlık alanında MR, BT, Ultrasonografi gibi tıbbi görüntüleme cihazları kullanılır. Bu cihazlar aracılığı ile elde edilen görüntüler ise derin öğrenme modellerine eğitilecek veriler olarak sunulur. Elde edilen veriler üzerinde genellikle herhangi bir özellik çıkarımı veya ön işleme adımı gerçekleştirilmez. Ele alınan görüntüler oluşturulan derin öğrenme modeline verilir ve modelin insan yapısına benzer olarak eğitim verileri ile öğrenmesi beklenir. Basit kedi ve köpek fotoğraflarının karşılaştırılması gibi hasta ve sağlıklı bireylerden alınan görüntüler derin öğrenme modellerine verilir. Ham hali ile ele alınan görüntülerin tasarlanan sistem tarafından doğru sınıflandırılması beklenir. Elde edilen model sonuçlarının başarılı olması halinde hastalık tespitlerinde uzmanlara kolaylık sağlanması muhtemeldir [78].


Evrişimli Sinir Ağları

Görüntü analizlerinin yapılmasında, çok katmanlı bir yapay sinir ağı olan Evrişimsel Sinir Ağı (ESA) kullanılmaktadır. ESA, filtrelemeye dayalı olarak çalışan bir çeşit derin öğrenme alt dalıdır. Burada ifade edilen filtreleme işlemi görüntülerdeki pikseller üzerinde yapılan matematiksel işlemler olarak da ifade edilebilir. Yapılan filtreleme işlemi sonucunda ise verinin önemli sayılan özelliklerinin ortaya çıkarılması veya belirgin hale getirilmesi amaçlanır. Görüntü pikselleri üzerinde gerçekleştirilen filtreleme işlemi Şekil 3.11’de gösterildiği gibi görselleştirilebilir.



Şekil 3.11. Pikseller üzerinde gerçekleşen filtreleme işlemi [79]

ESA’lar genellikle 3 ayrı katman halinde çalışır. Bu katmanlar Şekil 3.12’de gösterildiği gibi sırasıyla Evrişim Katmanı, Havuzlama Katmanı ve Tam Bağlı Katman olarak adlandırılır. Bu katmanlarda, görüntüye sırasıyla belirli işlemler uygulanarak ESA modelinin eğitiminin tamamlanması ve bir çıktı elde edilmesi beklenir.



Şekil 3.12.Evrişimli sinir ağı temel katman yapısı [80]

Evrişim katmanı olarak da ifade edebileceğimiz Evrişim katmanında görüntünün her bir pikseline ulaşılacak şekilde filtreleme işlemi uygulanır. Filtreler farklı piksel boyutları halinde uygulanabilirler. Uygulanan filtre ile asıl resmin arasındaki işlemler sonucunda yeni piksel değerleri oluşturulur. Sonuç olarak ise yeni boyutu ile görüntünün çıktı matrisi elde edilir. Bu matris ise filtrelenmiş görüntüyü ifade eder [81].

Evrişim katmanından sonra uygulanan Havuzlama katmanında ise piksel değerlerine yine bir filtreleme işlemi uygulanır. Bu katmanda farklı olarak gerçekleştirilen işlemde piksel değerlerinin maksimum veya ortalama değeri alınır. Filtrenin uygulandığı alandaki piksel değerlerinin maksimumu alınıyorsa bu işleme Maksimum Havuzlama adı verilir. Maksimum Havuzlama işlemi ile görüntüdeki önemli özelliklerin korunması sağlanır. Eğer bu adımda piksel değerlerinin ortalamasını alarak yeni değerler oluşturuluyorsa buna Ortalama Havuzlama adı verilir ve sonuç olarak görüntünün özellik haritası çıkartılmış olur [81].

Tam Bağlı Katmanı ise Evrişim ve Havuzlama katmanları üzerinde yapılan işlemlerin sonucunu almayı amaçladığımız katmandır. Elde edilen sonuçlar doğrultusunda görüntü bir sınıfa etiketlenmelidir. Evrişim ve Havuzlama katmanları sonucu elde edilen matris, görüntünün bir sınıfa ait olma olasılığını temsil eden vektöre dönüştürülür [81]. Bu vektör sonucuna göre görüntünün; hastalıklı/sağlıklı, iyi huylu/ kötü huylu gibi model eğitiminde elde etmek istediğimiz sonuca etiketlenmesi hedeflenir.

Literatürde ESA ile çeşitli medikal görüntülemeler üzerinde gerçekleştirilen farklı çalışmalar bulunabilir. Bu çalışmalara retina görüntülerinden diyabetik teşhisi, çeşitli X-Ray görüntüleri ile Covid-19 tespiti gibi örnekler verilebilir [82].

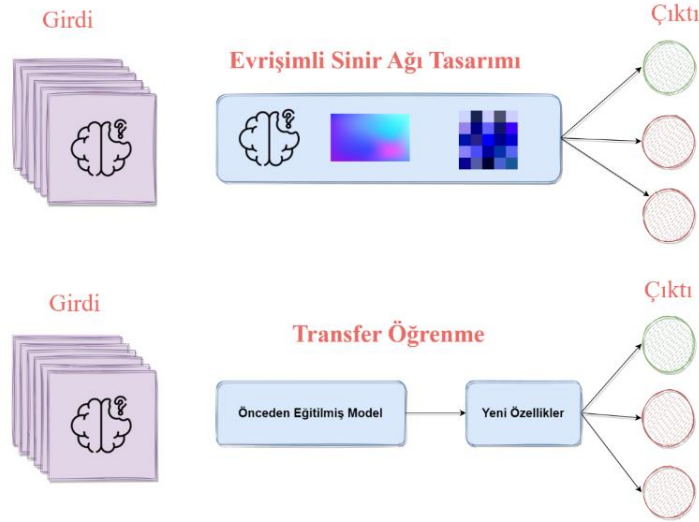
Transfer Öğrenme

Bir derin öğrenme modeli eğitilirken, Evrişim, Havuzlama ve Tam Bağlı katmanları, bir algoritma oluşturacak şekilde düzenlenir. Oluşturulan bu ağlarda veri setinin minimumda

kalması, yetersiz sayıda veri içermesiyle birlikte aşırı uyum veya yetersiz uyum problemleri ile karşılaşılabilir [83].

Aşırı uyum problemi, model tarafından eğitim verilerinin ezberlemesi olarak tanımlanabilir. Bu aşırı uyum problemi sonucunda; modelin, eğitim verileri dışında bir görsel ile karşılaşması halinde düşük oranlı başarımlar sergilemesi söz konusu olur [84]. Yetersiz uyum problemi ise aşırı uyumun tersi olarak nitelendirilen durumdur. Bu durumda model eğitildiği veri seti içerisindeki görselleri de başarılı bir şekilde tespit edemeyecek durumdadır [85]. Bu sorunların ortaya çıkmasına sebep, modelin içerdiği metriklerin zayıf veya yetersiz olarak nitelendirilebilecek durumda olmasıdır.

Model eğitimi sırasında modelin veya veri setinin yetersizliği halinde bu gibi durumlara çözüm olarak transfer öğrenme yöntemi kullanılır. Transfer öğrenmede, daha önce çok daha büyük bir veri seti üzerinde eğitilmiş ve yüksek doğruluk elde etmiş mimarilerin kullanılması söz konusudur. Bu yöntemde temel olarak büyük boyutlu veri kümelerinde eğitilen modellerin Tam Bağlı katmanlarına, hedeflenen eğitim verisinin eklenmesi ve eğitilmesi sağlanır. Bu sayede daha yüksek doğruluk oranına sahip daha başarılı bir model eğitimi gerçekleştirilebilir. Transfer öğrenme kullanımı ile daha önceden eğitilmiş modelin Şekil 3.13'te gösterildiği gibi özellik çıkarma ve ön işleme gibi adımları hazır olarak kullanılabilir. Bu sayede hız ve doğruluk oranı açısından daha yüksek başarıya sahip modeller eğitilmesi hedeflenir.



Şekil 3.13. Transfer öğrenme yapısı [86]


4. MATERYAL VE METOT

4.1. Materyal

4.1.1. Veri Seti

OASIS, ücretsiz ve açık kaynaklı bir biçimde kullanıma sunulan, beyinde görülen hastalıklar ile ilgili çalışmalarda kullanılan bir veri setidir [87]. OASIS veri seti Alzheimer hastalığı için en çok kullanılan veri setlerindendir, yapılan araştırmalara göre. Bu veri seti içerisinde Alzheimer hastalarının ve sağlıklı yetişkinlerin çeşitli sebeplerle alınmış MR görüntülerini barındırmaktadır. OASIS, beyin yapısı üzerinde meydana gelen değişiklikleri ve beynin işlevlerini inceleyen bilim insanları için kapsamlı bir kaynak niteliği taşımaktadır.


Veri seti içerisinde bulunan sağlıklı bireylerin MR görüntüsü; beyin işlevselliği ve bununla ilgili bir bilgi ağının geliştirilmesine olanak sağlayabilir. Bununla birlikte Alzheimer hastalığına sahip bireylerden alınan görüntüler sayesinde de Şekil 4.1’de gösterildiği gibi hastalığın insan beyni üzerindeki fiziksel etkilerinin gözlenmesi de mümkündür.



Şekil 4.1. Sağlıklı beyin ve Alzheimer hastalığına sahip beyin görüntüsü [88]


OASIS veri seti; 2005 yılında Washington Üniversitesi Alzheimer Araştırma Merkezi tarafından oluşturulmuş ve açık kaynaklı bir şekilde kullanıma sunulmuştur. İçerisinde fonksiyonel manyetik rezonans görüntüleme (fMRI) ve manyetik rezonans görüntüleme (MRI) gibi çeşitli yöntemlerle elde edilen beyin verileri bulunmaktadır. Veri seti, açık kaynaklı bir veri seti olarak sunulmuştur ve araştırmacılar tarafından kullanıma sunulmuştur. Veri seti, beyin görüntüleme verileri üzerinde çalışmak isteyen araştırmacılar için önemli bir kaynak olabilir. OASIS veri seti, Alzheimer hastalığı gibi önemli beyin hastalıklarının etkilerini anlamak için kullanılabilecek güçlü bir araçtır.

OASIS veri seti içerisinde toplanan Alzheimer hastalığına sahip hastaların farklı aşamalarda toplanan görüntüleri mevcuttur [89]. Bu çalışmada; yalnızca Alzheimer hastalığı öz niteliğine sahip hastaların verileri toplanmıştır. Elde edilen veriler 3 ayrı sınıf olarak ele alınmış ve Klinik Olarak Normal, HBB ve ÇHBB olarak ayrılmıştır. 174 adet hastadan toplanan veri içeriği Şekil 4.2’de gösterildiği gibidir.



Şekil 4.2. Veri seti içeriği

Bu sınıflar yalnızca Alzheimer hastalığı öz niteliği taşıyan hastalardan seçilmiştir. Veri seti, bu sınıfların kullanılması sayesinde, Alzheimer hastalığının farklı evrelerinde beyindeki fiziksel özelliklerin ne derecede değiştiği üzerinde çalışan araştırmacılar için değerli bir kaynak niteliği taşımaktadır. Ayrıca, farklı evrelerdeki hastaların verilerinin ayrı ayrı ele alınması ile, Alzheimer hastalığının etkilerinin daha iyi anlaşılmasına yardımcı olması hedeflenmiştir. Veri toplama aşamasında yalnızca Alzheimer hastalığı taşıyan ve normal olmak üzere 90 kadın 84 erkek hasta verisi ele alınmıştır. Hasta sayılarını ve veri dağılımlarını gösteren grafikler Şekil 4.3’te verildiği gibidir.



Şekil 4.3. Kadın ve erkek hasta sayılarının dağılım grafiği

OASIS veri seti, her geçen gün daha da ilerleyen sağlıkta yapay zekâ uygulamalarının geliştirilmesi için kıymetli bir kaynak niteliğindedir. Bu nedenle, OASIS veri seti, Alzheimer hastalığının erken teşhisini hedefleyen bu çalışmada da veri kaynağı olarak kullanılmıştır.

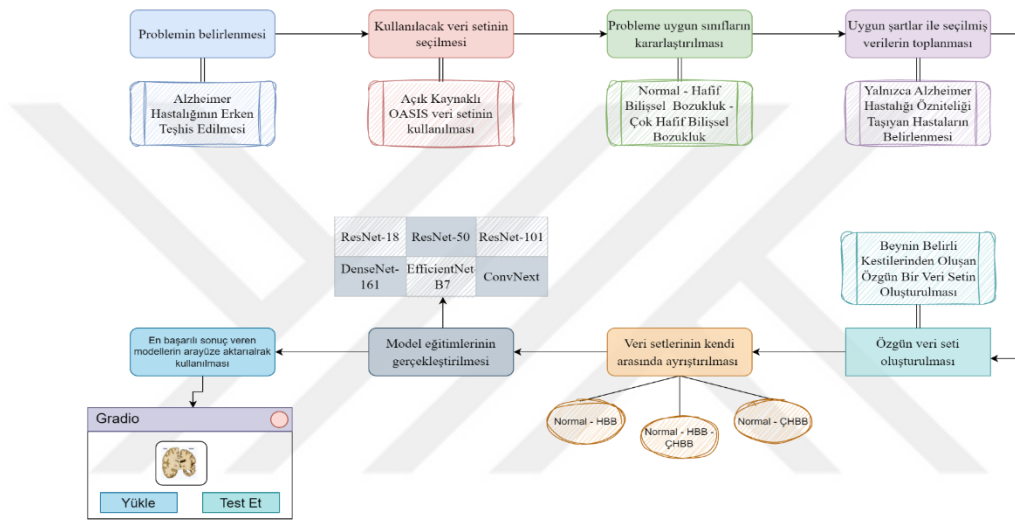
4.2. Metot

Bu çalışmada; Alzheimer hastalığının erken teşhisine ön ayak olabilecek bir sistem geliştirmesi hedeflenmiştir. Gerçekleştirilen çalışmanın ilk aşaması Alzheimer hastalığının erken teşhisi için kullanılabilecek veri setinin seçilmesidir. Alzheimer hastalığı üzerine yayınlanmış açık kaynaklı birçok hazır sınıflandırılmış veri seti bulunmaktadır. Bu çalışmada da açık kaynaklı olarak yayınlanan OASIS veri seti kullanılmıştır. OASIS veri seti içerisinde bulunan veriler değerlendirilerek hasta bazlı bir veri toplama süreci gerçekleştirilmiştir. Toplanan verilerin yalnızca Alzheimer hastalığı parametresi taşıyor olmasına ve Eğitim-Test olarak ayrılan verilerin farklı hastalara sahip olmasına dikkat edilmiştir.

Elde edilen verilerin hastalık teşhisleri ve sınırlandırıcı parametreler göz önünde bulundurulduğunda sayıca, denge problemine yol açacak oranda farklılık gösterdikleri gözlenmiştir. Görüntüler üzerinde herhangi bir ön işleme adımı gerçekleştirilmemiş ve ham hali ile kullanılmış olsa da denge probleminin çözülmesi için veri artırma ve azaltma işlemleri uygulanmıştır.

Eğitilen modeller Normal-HBB, Normal-ÇHBB, HBB-ÇHBB olmak üzere üç ayrı veri grubuna ayrılarak erken aşamada Alzheimer hastalarının, hastalık bulunmayan bireylerden ayrılmasının yanı sıra; hastalık aşamaları arasında da bir ayrım gerçekleştirilmesinin ve tedavi sürecine yardımcı olmasının önünün açılması hedeflenmiştir. Derin öğrenme yöntemleri kullanılarak sağlık alanında hastalık teşhisleri, acil vakaların erken teşhisi gibi birçok duruma yönelik çalışmalar yapılmaktadır. Bu çalışmada da erken teşhis edilmesi halinde; hastanın tedavi sürecinin başlaması, yaşam kalitesinin ve süresinin artırılması için yardımcı olabilecek bir sistemin geliştirilmesi amaçlanmıştır.


Yapılan çalışmada en başarılı modelin elde edilmesi ve teşhis aşamasında en doğru sonucun elde edilmesi amacı ile model hiper parametreleri üzerinde değişiklikler sağlanması, veri artırma ve azaltma yöntemlerinin kullanılması, Transfer Öğrenme yoluna gidilerek önceden eğitilmiş model parametrelerinden faydalanılması, hasta bazlı veri ayrımı yapılması gibi yöntemler uygulanmıştır. Geliştirilen modellerin doğrulama ve test verileri üzerinde gösterdikleri performanslar göz önünde bulundurulduğunda hastalık sürecinin erkenden teşhis edilmesine olanak sağlayacak sistemlerin geliştirilebilmesi için uygun hale getirilebileceği öngörülmektedir. Bu çalışmanın süreç tasarımı Şekil 4.4’de gösterildiği gibidir.



Şekil 4.4. Çalışma süreç tasarımı

ResNet

Artık Ağlar olarak bilinen ResNet 2015 yılında Kaiming He ve arkadaşları tarafından geliştirilmiş bir sinir ağı olarak tanımlanır. Bu sinir ağı ILSVRC ve COCO2015 yarışmalarında birçok alanda birincilik elde etmiştir [90]. Derin öğrenme mimarileri ortaya çıktığı yıllardan itibaren ağ ne kadar derinse başarı o kadar yüksek olur bakışı ile geliştiriliyordu [91]. Ancak bir süre sonra katman sayısı arttıkça başarının belirli bir seviyeye kadar artırılabilirdiği ve bu seviyeden sonra eğitilen modelin, gördüğü verileri ezberleyerek aşırı öğrenme gibi uyum problemleri sergilediği görüldü [92]. ResNet mimarisi bu problemlere çözüm olarak artık blok yapısı oluşturarak kısa yol bağlantıları geliştirdi. Bu kısa yol bağlantıları aracılığı ile bir veya birden fazla katman atlanarak eğitim gerçekleştirilmekte ve bu sayede aşırı uyum problemlerinin giderilmesi sağlanmaktadır. ResNet 50 mimarisinin katman gösterim Şekil 4.5’ teki gibidir.




Şekil 4.5. ResNet-50 mimarisinin katman yapısı [93]

ConvNext

Gerçekleştirilen çalışmada kullanılan modellerden biri de ConvNext modelidir. Bu model Liu ve arkadaşlarının 2022 yılında ortaya çıkardıkları ve 2020’ler için bir ConvNext olarak yayınlanan bir çalışmada önerilen modeldir [94]. Önerilen modelin Görü Transformatörü (Vit*) olarak bilinen mimari yapısından esinlenerek gerçekleştirildiği öne sürülmüştür [95].

Bu yapının Vit mimarilerinden daha başarılı sonuçlar elde ettiği çalışmada ConvNext saf bir ESA modeli olarak sınıflandırılmıştır. ConvNext modeli; mimari yapısı açısından Şekil 4.6’da gösterildiği gibi olan ConvNext, ResNet modelinin Vit mimari ailesinin tasarım ve teknikleri ile birleştirilerek geliştirilen ve çağdaşlaştırılan biçimi olarak tanımlanmaktadır.




Şekil 4.6. ConvNext mimarisi katman yapısı

Geliştirilen bir ESA modelinde doğrusallık ve karmaşıklık problemlerini engellemek adına aktivasyon fonksiyonları kullanılır. Bu modelde Geleneksel Aktivasyon fonksiyonlarından olan ReLU aktivasyon fonksiyonu yerine GeLU (Gauss Hatası Doğrusal Birimi) kullanarak mimari bir güncellemeye gidilmiştir. Benzer şekilde ESA mimarilerinde kullanılan normalizasyon fonksiyonu olan Toplu normalleştirme (BN) değil yerine Katman Normalleştirme (LN) kullanılarak mimari tasarımda özgün bir çalışma gerçekleştirilmiştir. ConvNext, mimari başarılarının ölçülmesinde etkili rol oynayan ImageNet-1K veri setini sınıflandırmada birçok güçlü mimari arasından birinci olmuş ve COCO veri seti ile nesne algılama, ADE20K görüntü segmentasyonu çalışmalarında ise Swin Transformers mimarisini geride bırakmıştır [96].

EfficientNet

EfficientNet 2019 yılında Google ekibinden Mingxing Tan ve Quoc V. Le tarafından ortaya atılmış güncel bir derin öğrenme mimarisidir [97]. Hesaplama açısından verimli olmayı hedefleyen bu mimari ImageNet veri setinde yüksek bir başarı oranı elde etmiştir. Bu mimaride ters artık blok ve swish aktivasyon fonksiyonları kullanılmaktadır. Swish aktivasyon fonksiyonu sigmoid ve lineer aktivasyon fonksiyonlarının çarpımı olarak hesaplanan bir aktivasyon fonksiyonudur. Bu çalışmada da katman yapısı Şekil 4.7’de gösterilen EfficientNet mimarisinin Transfer Öğrenme teknikleri ile kullanılmıştır.



Şekil 4.7. EfficientNet mimarisi katman yapısı [98]


4.2.1. Performans Ölçüm Yöntemleri

Makine Öğrenmesi ve derin öğrenme alanında, eğitilen modelin performansının ölçeklendirilebilmesi ve belirli bir değerlendirmeye tabi tutulabilmesi için performans ölçütleri hesaplanır. Bu ölçütlerin hesaplanmasının temelinde Karmaşıklık Matrisi ile elde edilen değerler üzerinden gerçekleştirilen matematiksel işlemler bulunur.

Karmaşıklık Matrisi (Confusion Matrix)

Model eğitilirken ilk aşamada elde edilen veri seti test ve eğitim verisi olarak ayrılır. Ayrıştırılan eğitim verisi üzerinde eğitilen veri daha önce karşılaşmadığı test verisi ile

tahminleme işlemini gerçekleştirir. Bu tahminlerden pozitif ve negatif olarak ayrılır. Bu sınıfların ne ölçüde başarılı şekilde tahmin edildiğini gösteren matris Karmaşıklık Matrisi Şekil 4.8’de ki gibi olarak elde edilir. Karmaşıklık Matrisi içerisinde Doğru Pozitif (TP), Yanlış Negatif(FN), Yanlış Pozitif(FP) ve Doğru Negatif(TN) olmak üzere 4 bölüm bulunmaktadır [99].



Şekil 4.8. Karmaşıklık Matrisi

Doğru Pozitif(DP): Test verisi içerisindeki pozitif değerler pozitif olarak tahmin edilmiştir. Pozitif sınıflar için doğru sınıflandırma yapıldığı durumlarda elde edilen değerdir.

Yanlış Negatif(YN): Test verisi içerisindeki pozitif değerler negatif olarak tahmin edilmiştir. Pozitif sınıflar için yanlış tahminleme işlemi yapıldığı durumlarda elde edilen değerdir.

Yanlış Pozitif(YP): Test verisi içerisindeki negatif değerler pozitif olarak tahmin edildiği yani negatif değerler için yanlış sınıflandırma yapıldığı durumlarda elde edilen değerdir.

Doğru Negatif(DN): Test verisi içerisindeki negatif değerler negatif olarak tahmin edilmiş ve doğru sınıflandırma yapılmış durumlarda elde edilen değerdir.

4.2.2. Performans Değerlendirme Ölçütleri

Doğruluk (Accuracy): Model eğitimi sonucunda karmaşıklık matrisi üzerinde gerçekleştirilen hesaplamalar ile modelin performans ölçütleri hesaplanabilir. Bu ölçütlerden biri olan doğruluk ölçütü doğru tahmin edilen değerlerin bütün test verisi sayısına oranlanması ile elde hesaplanır. Temelde modelin doğru çalışıp çalışmadığına dair fikir vererek modeli karakterize eder [100]. Doğruluk ölçütünün hesaplanması için gerekli hesaplama Denklem 4.2.2.1’de verildiği gibidir.

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (4.2.2.1)$$

Kesinlik (Precision): Kesinlik değeri model tahminlerindeki kesinlik durumunu ifade eder. Modelin test verisi üzerinden pozitif olarak tahminleme işlemi gerçekleştirdiği değerlerin gerçekte hangi oranda pozitif olduğunun hesaplanması durumudur [100]. Kesinlik ölçütünün hesaplanması için gerekli hesaplama Denklem 4.2.2.2’de gösterildiği şekilde gerçekleştirilir.

$$Precision = \frac{TP}{TP+FP}$$

(4.2.2.2)

Duyarlılık (Recall): Modelin özellikle bir sınıflandırma problemi olarak tanımlandığı durumlarda sıklıkla kullanılan bir performans ölçüm yöntemidir. Bu ölçüt ile pozitif tahmin edilmesi gereken sınıf değerlerinin hangi oranda pozitif olarak seçildiğini hesaplanır. Duyarlılık ölçütünün yüksek olması durumundan model duyarlılığının da yüksek olduğu çıkarımı yapılır [100]. Duyarlılık ölçütünün hesaplanması için gerekli işlemler Denklem 4.2.2.3’de verildiği gibidir.

$$Recall = \frac{TP}{(TP+FN)} \quad (4.2.2.3)$$

F1-Puanı(F1-Score): Kesinlik ve Duyarlılık performans ölçütlerinin harmonik ortalaması alınarak elde edilen bir performans ölçüm yöntemidir. Bu yöntem ile model başarısındaki uç durumların kontrolünün sağlanması hedeflenmektedir [100]. Doğruluk ölçütünün hesaplanması için gerekli işlemler Denklem 4.2.2.4’te verildiği haliyle kullanılmaktadır.

$$F1 - Score = 2 * \frac{Precision*Recall}{Precision+Recall} \quad (4.2.2.4)$$

5. BULGULAR VE TARTIŞMA

Bu tez çalışmasında Alzheimer hastalığının erken teşhisinin derin öğrenme yöntemleri ile sağlanması hedeflenmiştir. Erken teşhis amacına hizmet eden üç ayrı çalışma grubu için model eğitimleri gerçekleştirilerek elde edilen sonuçlar karşılaştırılmıştır.

Bu çalışma grupları Normal-HBB, Normal-ÇHBB ve HBB-ÇHBB sınıflarının ayrı ayrı ele alınması ile oluşturulmuştur. Bu sayede erken seviye Alzheimer hastalığına sahip bireylerin Kontrol gruplarından ayrılabilmesi ve aynı zamanda hastalık aşamalarının da birbirlerinden ayırt edilebilmesi amaçlanmıştır.

Çalışma gruplarının her biri için Eğitim, Doğrulama ve Test klasörleri belirli kriterler ele alınarak oluşturulmuştur. Eğitimler sırasında karşılaşılabilecek problemler göz önünde bulundurularak belirli hiper parametre ayarlamaları gerçekleştirilmiştir. Bu hiper parametre bilgileri Tablo 5.1’de gösterildiği gibidir.

Tablo 5.1. Model eğitimlerinde kullanılan hiper parametre değerleri

Hiper Parametre Adı	Hiper Parametre Değeri
Eğitim Tur Sayısı	100
Öğrenme Katsayısı	Her eğitim için optimum değer hesaplanmıştır.
Eğitim – Test Oranı	%90 - %10
Yığın Boyutu	Her eğitim için optimum değer ele alınmıştır. (16-32)
Görüntü Boyutu	Her eğitim için optimum değer ele alınmıştır. (256-512)

Oluşturulan her bir çalışma grubu için altı adet ayrı transfer öğrenme modeli eğitilmiştir. Çalışma gruplarının eğitimi sırasında belirli veri sayıları ile çalışılmasının yanında denge problemlerine yol açabilecek veri sayısı farklılıkları da bulunmaktadır. Bu farklılıklar göz önüne alındığında eğitim sırasında oluşabilecek aşırı uyum ve yetersiz uyum problemleri için önlemler alınmıştır. Veri sayıları; çalışma grupları göz önüne alınarak aşağı veya yukarı yönde veri sayısı dengeleme işlemleri gerçekleştirilmiştir. Bu işlemler her çalışma grubu için ayrı ayrı gerçekleştirilmiştir.

Bu şartların sağlanması ile alınan eğitim sonuçlarına göre en yüksek doğruluk oranına sahip modeller belirlenerek; kullanılabilir ve test edilebilir şekilde yerel sunucuda çalıştırılabilir olarak bir web arayüzüne entegre edilmiştir. Ele alınan her bir çalışma grubu için alınan doğruluk, değerleri Tablo 5.2’de verildiği gibidir.

Tablo 5.2. Çalışma gruplarından elde edilen doğrulama ve test başarı oranları

Normal – HBB Çalışma Grubu		
Eğitilen Mimari	Doğrulama Verisi Başarı Oranı	Test Verisi Başarı Oranı
ResNet-18	99.4	83.91
ResNet-50	99.80	95.40
ResNet-101	99.05	80.10
DenseNet-161	99.80	92.07
EfficientNet-B7	98.07	93.02
ConvNext		
Normal – ÇHBB Çalışma Grubu		
ResNet-18	99.80	92.22
ResNet-50	99.80	92.16
ResNet-101	99.90	84.52
DenseNet-161	99.80	95.90
EfficientNet-B7	99.51	95.01
ConvNext	99.90	97.53
HBB – ÇHBB Çalışma Grubu		
ResNet-18	90.72	86.89
ResNet-50	92.89	91.40
ResNet-101	93.28	74.12
DenseNet-161	92.59	83.06
EfficientNet-B7	93.08	73.10
ConvNext	99.90	92.17

5.1. Normal-HBB Çalışma Grubu

Ele alınan çalışma gruplarından ilki Normal – HBB sınıfları için ele alınmıştır. Alzheimer hastalığı şüphesi ile doktor kontrolünde bulunan ancak herhangi bir tanı konulmamış hastalardan oluşan bir veri sınıfı oluşturulmuştur. Oluşturulan veri setinde 1572 Normal ve 1743 HBB sınıfına ait hasta görüntüsü bulunmaktadır. 3 boyutlu MR görüntüsü olarak alınan ve model eğitimi öncesinde kesitler halinde bölünerek veri seti oluşturulmuştur. Ele alınan çalışma grubunda veri toplama aşamasında bir denge problemi oluşabileceği göz önüne bulundurulmuştur. Bu sebeple Normal sınıfına aşağı yönlü bir veri dengeleme işlemi uygulanmıştır. Bu işlem sonucunda Tablo 5.3'te verildiği gibi toplamda 1206 Normal ve 1284

HBB görüntüsünden oluşan eğitim, 366 Normal ve 459 HBB görüntüsünden oluşan test verisi kullanılmıştır.

Tablo 5.3. Normal-HBB çalışma grubu veri sayıları

Sınıf	Eğitim Veri Sayısı	Test Veri Sayısı
Normal	1206	366
HBB	1284	459
Toplam	2490	825


Normal-HBB çalışma grubunda ResNet-18, ResNet-50, ResNet101, DenseNet161, EfficientNet-B7, ConvNext mimarileri kullanılarak derin öğrenme modelleri eğitilmiştir. Bu modeller içerisinde ele alınan parametreler optimize edilmesi gereken öğrenme oranı parametresi hariç benzer seçilmiş ve Alzheimer hastalığının erken teşhisi için en başarılı mimarinin elde edilmesi amaçlanmıştır.

Eğitilen modellerin daha önce karşılaşmadığı, hasta bazlı olarak ayrılmış test verilerine ait doğruluk oranları hesaplanmıştır. Bu doğruluk oranlarının yanında Doğruluk, Kesinlik ve F1-Skoru oranları da Tablo 5.4'te ayrıntılı bir şekilde verilmiştir.

Tablo 5.4. Normal-HBB çalışma grubu için performans metrik sonuçları


Model	Doğruluk	Kesinlik	Duyarlılık	F1-Puanı
ResNet-18	83.91	99.52	98.39	88.27
ResNet-50	95.40	98.34	90.00	96.82
ResNet-101	80.10	97.95	92.44	85.82
DenseNet-161	92.07	97.34	94.50	93.99
EfficientNet-B7	93.02	92.20	87.60	95.09
ConvNext	94.50	91.55	86.51	95.59

Eğitilen modellerin doğrulama verisi üzerinde yaptığı hatalı tahmin sayısı ile test verileri üzerinde yaptığı hatalı tahmin sayısı birbirinden farklıdır. Eğitilen modellerin; test verilerinden %10 oranında ayrılarak kullanılan doğrulama verileri ile karmaşıklık matrisleri elde edilmiştir. Doğrulama verileri ile alınan sonuçlara ait karmaşıklık matrisleri Şekil 5.1'de gösterildiği gibidir.




Şekil 5.1. Normal-HBB gurubu modellerinde doğrulama verilerinden elde edilen karmaşıklık matrisleri

Bunun yanında test verilerinden elde edilen karmaşıklık matrisleri, dışarıdan alınan verilerle yapılan testler sonucunda elde edilmiştir. Bu testlerin gerçekçi sonuç verebilmesi için daha önce model eğitimi sırasında eğitim veya doğrulama verilerinde ele alınan hastalardan herhangi bir MR görüntüsü veya kesit içermemektedir. Bu yüzden de en başarılı modelin belirlenmesinde test sonuçlarının da etkili olup Şekil 5.2’de bütün modellere ait karmaşıklık matrisleri verilmiştir.




Şekil 5.2. Normal-HBB gurubu modellerinde test verilerinden elde edilen karmaşıklık matrisleri

Eğitilen modellerin başarı oranları ele alındığında; model eğitimi sırasında gerçekleşebilecek olan aşırı uyum ve yetersiz uyum problemleri ile karşılaşılma olasılığına dikkat edilmiştir. Bu uyum problemlerinin tespit edilebilmesi için eğitim tur sayıları esnasında alınan kayıp oranları önem arz etmektedir. Eğitim verilerinden ve doğrulama verilerinden elde edilen kayıp oranları arasındaki ilişkiler karşılaştırmalı olarak incelenmiştir. Bu bakımdan gerçekleşen eğitimlerin kayıp grafikleri ayrıntılı bir şekilde incelenmiş olup herhangi bir uyum problemi ile karşılaşmadığı gözlemlenmiştir. Model eğitimleri sırasında elde edilen kayıp grafikleri Şekil 5.3'te verildiği gibidir.



Şekil 5.3. Normal-HBB grubu modellerinden elde edilen kayıp fonksiyonları

Ele alınan karmaşıklık matrisleri, kayıp grafikleri ve doğruluk oranları incelendiğinde en yüksek test başarısına ResNet-50 modelinin ulaştığı gözlemlenmiştir. Bu model dışarıdan alınan verilerle test edilerek %95.40 oranında doğruluk sağlamıştır. Eğitilen modelin gerçek zamanlı kullanımını test edebilmek adına model bir web arayüzüne aktarılmış ve bu sayede herhangi bir hastadan alınan MR görüntüsü ile test edilebilir duruma getirilmiştir. Bu aşamada yalnızca kişisel bilgisayar ortamında kullanılabilir bu arayüz aktarımı sayesinde, eğitilen modellerin gerçek zamanlı olarak kullanılabilmesi konusunda umut verici sonuçlar elde edilmiştir. Modelin web arayüzüne aktarılarak test edildiği bir örneğe Şekil 5.4'te yer verilmiştir.



Şekil 5.4. Normal-HBB grubu ile eğitilen ResNet-50 modelinin web sayfası üzerinde örnek gösterimi

5.2. Normal-ÇHBB Çalışma Grubu

Bu tez çalışmasında ele alınan çalışma gruplarından biri de Normal – ÇHBB sınıflarından oluşmaktadır. Çok hafif bilişsel bozukluk aşaması, Alzheimer hastalığının ilk aşamalarındandır. Bu aşamada hastalık henüz belirtilerini net bir şekilde göstermeye başlamadığı için tespit edilmesi oldukça zor ve önemli olan bir aşamadır. Bu sebeple bu çalışmada da Normal ve ÇHBB aşamalarının ele alındığı bir çalışma grubu üzerinde, erken teşhisin hedeflendiği deneyler gerçekleştirilmiştir.

Bu çalışma grubunda Normal grubu ve ÇHBB grubu olmak üzere iki sınıftan oluşan bir veri seti kullanılmıştır. Bu veri seti içerisinde toplam 6053 Normal ve 5746 ÇHBB aşamasındaki hastaların MR görüntüsüne ait kesitleri bulunmaktadır. Çalışmada kullanılan veri sayıları Tablo 5.5’te gösterildiği gibidir.

Tablo 5.5. Normal-ÇHBB çalışma grubu veri sayıları


Sınıf	Eğitim Veri Sayısı	Test Veri Sayısı
Normal	5225	828
ÇHBB	5030	716
Toplam	10255	1544

Çalışma grubu üzerinde eğitilen derin öğrenme modellerinde hiper parametre seçimleri aynı veya yakın seçilmiş olup en başarılı modelin objektif bir biçimde ortaya konulması hedeflenmiştir. Bu seçimler içinden öğrenme katsayısı, yığın boyutu ve görüntü boyutu hiper parametreleri; eğitilen model için alınabilecek optimum değerleri hesaplanarak kullanılmıştır. Kullanılan hiper parametre değerleri ve değer aralıkları Tablo 5.6’da verildiği gibidir.

Tablo 5.6. Normal-ÇHBB çalışma grubu ile eğitilen modellerin hiper parametre değerleri

Hiper Parametre Adı	Hiper Parametre Değeri
Eğitim Tur Sayısı	100
Öğrenme Katsayısı	Her eğitim için optimum değer hesaplanmıştır.
Eğitim – Test Oranı	%90 - %10
Yığın Boyutu	Her eğitim için optimum değer ele alınmıştır. (16-32)
Görüntü Boyutu	Her eğitim için optimum değer ele alınmıştır. (256-512)

Normal – ÇHBB grubu için altı adet derin öğrenme modeli eğitilmiştir. Sırası ile ResNet-18, ResNet-50, ResNet-101, DenseNet-161, EfficientNet-B7, ConvNext mimarileri kullanılmıştır. Ele alınan model eğitimleri sırasında doğrulama ve test işlemleri birbirinden tamamen farklı hastalar üzerinde gerçekleştirilmiştir. Model eğitimi sırasında görüntüler; %90 eğitim, %10 doğrulama verisi olacak şekilde ayrılmıştır. Eğitilen modellerin doğrulama verileri ile elde edilen karmaşıklık matrisleri Şekil 5.5’te verildiği gibidir.



Şekil 5.5. Normal-ÇHBB grubu modellerinde doğrulama verilerinden elde edilen karmaşıklık matrisleri

Test verileri ise hasta bazlı olarak ayrılmış; eğitim veya doğrulama aşamasında kullanılan hastalardan herhangi bir kesit içermemesine dikkat edilmiştir. Bu aşamada en başarılı model seçimi için eğitilen modellerin test verileri üzerinde gösterdikleri başarılar göz önünde

bulundurulmuştur. Bu verilerin eğitilen model üzerinde test edilmesi sonucu elde edilen karmaşıklık matrisleri Şekil 5.6’da verildiği gibidir.




Şekil 5.6. Normal-ÇHBB gurubu modellerinde test verilerinden elde edilen karmaşıklık matrisleri

Test sonuçları ile elde edilen karmaşıklık matrislerinden yola çıkılarak en başarılı modelin belirlenmesi gerçekleştirilebilir. Bu aşamada en yüksek doğruluk oranının test verilerinden alınmış olması göz önünde bulundurulmuştur. Bunun yanında da eğitilen modelin test aşamasında gösterdiği doğruluk, hassasiyet, duyarlılık ve F1-Skoru oranları da Tablo 5.7’de verilmiştir. Bu oranlar göz önünde bulundurulduğunda en başarılı modelin ConvNext mimarisi ile eğitildiği görülmektedir.

Tablo 5.7. Normal-ÇHBB çalışma grubu için performans metrik sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1-Puanı
ResNet-18	92.22	89.01	88.07	91.61
ResNet-50	92.16	99.15	98.89	94.21
ResNet-101	84.52	94.21	91.97	87.94
DenseNet-161	95.90	99.32	93.14	96.39
EfficientNet-B7	95.01	99.88	99.84	95.61
ConvNext	97.53	99.88	99.85	97.30


Model doğruluğu ve değerlendirme metriklerinin geçerliliği aşamasında modelin herhangi bir aşırı uyum ve yetersiz uyum problemine dahil olmadığına tespiti gerçekleştirilmiştir. Bu uyum problemlerinin kontrolü sırasında test verilerinden alınan sonuçların yanında Şekil 5.7’ de verildiği gibi kayıp fonksiyonları da göz önünde bulundurulmaktadır. Kayıp grafikleri göz önüne alındığında eğitilen modellerde herhangi bir uyum problemi ile karşılaşılması söylenemez.



Şekil 5.7. Normal-ÇHBB grubu modellerinden elde edilen kayıp fonksiyonları

Eğitilen modellerin doğruluk, kesinlik, duyarlılık, F1-Skoru oranları Tablo 5.7 de verilmiştir. Bu değerler göz önünde bulundurulduğunda Normal - ÇHBB aşamalarının en yüksek doğruluk oranı ile sınıflandırılmasını ConvNext Mimarisi gerçekleştirmiştir.

Bu çalışma grubunda da elde edilen en başarılı sonuçlar üzerinde testlerin gerçekleştirilebilmesi ve gerçek zamanlı kullanım olanağının sağlanmasına ön ayak olunabilmesi hedeflenmiştir. Bu hedef doğrultusunda ConvNext modeli bir web arayüzüne entegre edilmiştir. Web arayüzü kullanılarak oluşturulan test ortamı şekil 5.8 de örneklenmiştir. Şekilde kullanılan test görüntüsü; test veri setinden alınan görüntülerden biridir.



Şekil 5.8. Normal-ÇHBB grubu ile eğitilen ConvNext modelinin web sayfası üzerinde örnek gösterimi

5.3. HBB – ÇHBB Çalışma Grubu

Bu tez çalışmasında; derin öğrenme tekniklerinin uygulandığı çalışma gruplarından biri Alzheimer hastalığının ilk aşamaları olan HBB-ÇHBB çalışma grubudur. Bu grubun ele alınmasındaki temel amaç Alzheimer hastalığının erken aşamalarının da birbirlerinden ayırt edilebiliyor olmasını sağlamaktır. Hastalık aşamalarının birbirinden ayrılması ile tedavi yöntemlerinin ve aşamalarının birbirinden ayrılması amaçlanmıştır. Bu amaç doğrultusunda daha doğru bir tedavi uygulaması ile hastaların yaşam süreçlerinin iyileştirilmesine katkı sağlanması hedeflenmiştir.

HBB-ÇHBB çalışma grubunda ele alınan görüntüler için veri toplama aşamasında bir denge problemi olduğu görülmektedir. Bu aşamada eğitilen modellerin uyum problemleri ile karşılaşmaması ve daha etkili bir teşhis çalışması gerçekleştirilmesi adına veri sayılarında düzenlemeye gidilmiştir. HBB-ÇHBB çalışma grubu için gerçekleştirilen çalışmada HBB sınıfında bulunan veriler için veri artırma yoluna gidilmiştir. Veri artırma uygulamaları sonucunda elde edilen veri sayıları Tablo 5.8’de gösterildiği gibidir.

Tablo 5.8. HBB-ÇHBB çalışma grubu veri sayıları


Sınıf	Eğitim Veri Sayısı	Test Veri Sayısı
HBB	5108	459
ÇHBB	5030	716
Toplam	10138	1175

HBB-ÇHBB çalışma grubu üzerinde eğitimler; en başarılı ve en yeni transfer öğrenme mimarilerinin kullanımı ile gerçekleştirilmiştir. Bu model eğitimleri esnasında en başarılı modelin

seçilmesi amaçlanmıştır. En başarılı modelin seçilebilmesi ve HBB-ÇHBB aşamalarının sınıflandırılmasında en başarılı mimarinin belirlenebilmesi için belirli hiper parametre seçimleri yapılmıştır. Bu hiper parametre seçimlerinde eğitilen modellerin tamamı için optimum değer gerektiren parametrelerin seçimleri ayrı ayrı gerçekleştirilmiştir. Bunun dışında kalan hiper parametreler bütün mimariler için ortak seçilerek gerçek zamanlı uygulamalarda da en doğru sonucu verebilecek mimarinin ortaya çıkarılması amaçlanmıştır. Modeller için kullanılan parametre değerleri Tablo 5.1’de ve Tablo 5.6’da gösterildiği gibidir.


HBB-ÇHBB çalışma grubu için de diğer gruplarda olduğu gibi toplam altı adet mimari ile derin öğrenme modelleri eğitilmiştir. Bu mimariler sırası ile Sırası ile ResNet-18, ResNet-50, ResNet-101, DenseNet-161, EfficientNet-B7, ConvNext olarak seçildi. Bu model eğitimleri sırasında gerçekçi sonuçlar alınabilmesi ve gerçek zamanlı kullanım olanağının test edilebilmesi adına Eğitim ve Test verileri hasta bazlı bir biçimde ayrılmıştır. Eğitim ve Test klasörleri içerisinde aynı hastaya ait farklı kesitler bulundurulmamasına ve tamamen farklı hastalardan oluşturulmasına dikkat edilmiştir.

Model eğitimleri sırasında eğitim ve doğrulama verileri de birbirinden %10 doğrulama ve %90 eğitim verisi olacak şekilde ayrılmıştır. Eğitilen ResNet-18, ResNet-50, ResNet-101, DenseNet-161, EfficientNet-B7, ConvNext modellerinden doğrulama verilerine ait derin öğrenme modellerinden karmaşıklık matrisleri elde edilmiş ve en başarılı modeller doğruluk oranı ile yorumlanmıştır. Elde edilen karmaşıklık matrisleri Şekil 5.9’da gösterildiği gibidir.



Şekil 5.9.HBB-ÇHBB gurubu modellerinde doğrulama verilerinden elde edilen karmaşıklık matrisleri

Eğitilen modeller Test klasörü ile modelin daha önce görmediği hastalara ait kesitler üzerinde test edilmiştir. Eğitilen modelin daha önce karşılaşmadığı bir hasta verisi ile başarısının ölçülmesi ve doğruluk oranının gerçekçi bir biçimde ele alınması hedeflenmiştir. Gerçekleştirilen model testi sonucunda her model için karmaşıklık matrisleri elde edilmiş ve performans değerlendirme metrikleri kullanılarak sonuçlar yorumlanmıştır. Yapılan testler sonucunda elde edilen karmaşıklık matrisleri Şekil 5.10’da gösterildiği gibidir.



Şekil 5.10. HBB-ÇHBB gurubu modellerinde test verilerinden elde edilen karmaşıklık matrisleri


Test verilerinin eğitilen model tarafından sınıflandırılması ile elde edilen karmaşıklık matrisleri üzerinden performans metriklerinin hesaplaması yapılmaktadır. Bu metriklerden yola çıkılarak en başarılı model belirlenmiştir. Bu aşamada en yüksek doğruluk oranının test verilerinden alınmış olması göz önünde bulundurulmaktadır. Bunun yanında da eğitilen modelin test aşamasında gösterdiği doğruluk, hassasiyet, duyarlılık ve F1-Skoru oranları da Tablo 5.9’da verilmiştir. Bu oranlar da göz önüne alınarak değerlendirildiğinde en başarılı modelin ConvNext mimarisi ile eğitildiği sonucuna ulaşılmıştır.

Tablo 5.9. HBB-ÇHBB çalışma grubu için performans metrik sonuçları

Model	Doğruluk	Kesinlik	Duyarlılık	F1-Puanı
ResNet-18	86.89	68.85	82.45	77.17
ResNet-50	91.40	80.39	88.55	87.03
ResNet-101	74.12	63.33	72.73	64.01

DenseNet-161	83.06	57.30	78.20	71.56
EfficientNet-B7	73.10	64.71	76.00	61.94
ConvNext	92.17	94.99	96.48	88.89


Alzheimer hastalığının aşamalarını sınıflandırmada en başarılı olan model seçimi gerçekleştirilirken model eğitimi sırasında herhangi bir aşırı uyum ve yetersiz uyum problemi ile karşılaşılma- mış olması önemlidir. Bu uyum problemlerinin kontrolü; eğitim aşamasında elde edilen kayıp grafiklerinin incelenmesi ile gerçekleştirilir. HBB-ÇHBB çalışma grubunda eğitilen modellere ait kayıp grafikleri Şekil 5.11’de gösterildiği gibidir. Kayıp grafikleri incelendiğinde herhangi bir uyum problemi ile karşılaşılma- dığı gözlenmiştir.



Şekil 5.11. HBB-ÇHBB gurubu modellerinden elde edilen kayıp fonksiyonları

Eğitilen modeller doğruluk, kesinlik, duyarlılık, F1-Skoru oranları ile değerlendirildiğinde HBB-ÇHBB çalışma grubuna ait en yüksek doğruluk oranının ConvNext mimarisi ile sınıflandırıldığı sonucuna ulaşılmıştır.

HBB-ÇHBB çalışma grubuna ait sonuçların gerçek zamanlı olarak test edilebilirliği oldukça önemlidir. Bu gerçek zamanlı çalışma testleri modelin bir web arayüzüne aktarılması ile gerçekleştirilmiştir. Web arayüzüne aktarılan modelin gerçek hayat problemlerinde de kullanılabilmesi hedeflenmiştir. Bu hedef doğrultusunda ConvNext mimarisi ile eğitilen modelin bir web arayüzüne aktarılarak oluşturulan test ortamı Şekil 5.12’de gösterildiği gibi örneklenmiştir.



Şekil 5.12. HBB-ÇHBB grubu ile eğitilen ConvNext modelinin web sayfası üzerinde örnek gösterimi

6. SONUÇLAR

Bu tez çalışmasında; Alzheimer hastalığı erken teşhisinin desteklenmesi amacı ile derin öğrenme modelleri geliştirilmiştir. Erken teşhise yönelik Alzheimer hastalığı aşamalarının sınıflandırıldığı çalışma grupları oluşturulmuştur. Oluşturulan çalışma gruplarında Normal-HBB ve ÇHBB aşamaları sınıflandırılmıştır. Bu çalışma grupları ile hastalık teşhisinin erken aşamada gerçekleştirilebilmesi ve erken aşama seviyelerinin birbirlerinden ayırt edilebilmesi amaçlanmıştır.

Çalışmada OASIS veri setinden toplanan ve üç sınıftan elde edilen hasta görüntüleri kullanılmıştır. Oluşturulan bu gruplarda veri sayıları arasında oluşan farklılıkların denge problemlerine yol açacak seviyede olması halinde veri artırma veya azaltma yoluna gidilmiştir. Bu sayede eğitilen modellerin uyum problemi yaşamasının önüne geçilmesi ve daha doğru sonuçlar elde etmesi hedeflenmiştir. Çalışma gruplarının tamamı benzer hiper parametreler kullanılarak ile ResNet-18, ResNet-50, ResNet-101, DenseNet-161, EfficientNet-B7, ConvNext mimarileri ile eğitilmiştir.

Normal – HBB çalışma grubunda 1572 Normal ve 1743 HBB sınıfına ait olmak üzere toplam 2490 görüntü eğitim aşamasında kullanılmıştır. Bu çalışma grubunda Normal ve HBB verileri arasında oluşabilecek denge problemlerine karşı aşağı yönlü dengelem işlemi gerçekleştirilmiştir. Tamamı benzer hiper parametreler kullanılarak ile ResNet-18, ResNet-50, ResNet-101, DenseNet-161, EfficientNet-B7, ConvNext mimarileri ile eğitimler gerçekleştirilmiştir. Eğitilen modeller 825 görüntü üzerinde test edilmiştir. Yapılan testler sonucunda en yüksek doğruluk oranına %95.40 ile ResNet-50 mimarisi kullanılarak eğitilen model ulaşmıştır.

Normal – ÇHBB çalışma grubunda 5108 Normal ve 5030 HBB sınıfına ait olmak üzere toplam 10.138 görüntü eğitim aşamasında kullanılmıştır. Benzer hiper parametreler ile eğitilen altı adet model eğitimi gerçekleştirilmiştir. Eğitilen modeller 1544 görüntü üzerinde test edilmiştir. Bu testler sonucunda en başarılı sonuç; ConvNext modeli tarafından %97.53 doğruluk oranı ile elde edilmiştir.

HBB ve ÇHBB aşamaları ile oluşturulan çalışma grubunda 5108 HBB ve 5030 ÇHBB sınıfına ait olmak üzere toplam 10138 görüntü eğitim aşamasında kullanılmıştır. Eğitilen altı adet model üzerinde benzer hiper parametre değerleri kullanılmıştır. Eğitim aşamasında modellerin kayıp fonksiyonları incelenerek aşırı uyum veya yetersiz uyum ile karşılaşmadıkları görülmüştür.

Eğitilen modeller 1175 görüntü üzerinde test edilmiştir. Bu testler sonucunda en başarılı sonuç; ConvNext mimarisi ile eğitilen modelden %97.53 doğruluk oranı ile elde edilmiştir.

Elde edilen sonuçlar değerlendirildiğinde Normal-ÇHBB ve HBB-ÇHBB çalışma gruplarında ConvNext modelinin Normal-HBB çalışma grubunda ise ResNet-50 mimarisinin en yüksek doğruluk oranına sahip olduğu gözlenmiştir. En başarılı modellerin gerçek zamanlı kullanılabilirliği de çalışma içerisinde bir web sayfasına entegre edilmeleri sağlanarak test edilmiştir. Çalışma gruplarının erken aşama görüntüleri ile oluşturulmasının, Alzheimer hastalığı üzerinde erken teşhise umut olması amaçlanmıştır. Elde edilen en başarılı modeller bir web arayüzüne entegre edilerek gerçek zamanlı kullanılabilir bir karar destek sistemi tasarlanmıştır.



KAYNAKLAR

- [1] Sethi, M., Ahuja, S., Rani, S., Koundal, D., Zaguia, A., & Enbeyle, W. (2022). An Exploration: Alzheimer's Disease Classification Based on Convolutional Neural Network. BioMed Research International, 2022.
- [2] Acharya, U. R., Fernandes, S. L., WeiKoh, J. E., Ciaccio, E. J., Fabell, M. K. M., Tanik, U. J., ... & Yeong, C. H. (2019). Automated detection of Alzheimer's disease using brain MRI images—a study with various feature extraction techniques. *Journal of Medical Systems*, 43(9), 1-14.
- [3] “Alzheimer Disease International Conference 2022”. Erişim 26 Aralık 2022. <https://www.alzint.org/what-we-do/adi-conference/adi-conference-2022/>.
- [4] Khan, S., & Yairi, T. (2018). A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 107, 241-265.
- [5] “ADNI | Alzheimer's Disease Neuroimaging Initiative”. Erişim 26 Aralık 2022. <https://adni.loni.usc.edu/>.
- [6] Daniel S. Marcus, Anthony F. Fotenos, John G. Csernansky, John C. Morris, Randy L. Buckner; Open Access Series of Imaging Studies: Longitudinal MRI Data in Nondemented and Demented Older Adults. *J Cogn Neurosci* 2010; 22 (12): 2677–2684. doi: <https://doi.org/10.1162/jocn.2009.21407>
- [7] Acharya, U. R., Fernandes, S. L., WeiKoh, J. E., Ciaccio, E. J., Fabell, M. K. M., Tanik, U. J., ... & Yeong, C. H. (2019). Automated detection of Alzheimer's disease using brain MRI images—a study with various feature extraction techniques. *Journal of Medical Systems*, 43(9), 1-14.
- [8] Raza, M., Awais, M., Ellahi, W., Aslam, N., Nguyen, H. X., & Le-Minh, H. (2019). Diagnosis and monitoring of Alzheimer's patients using classical and deep learning techniques. *Expert Systems with Applications*, 136, 353-364.
- [9] Puente-Castro, A., Fernandez-Blanco, E., Pazos, A., & Munteanu, C. R. (2020). Automatic assessment of Alzheimer's disease diagnosis based on deep learning techniques. *Computers in Biology and Medicine*, 120, 103764.
- [10] Previtali, F., Bertolazzi, P., Felici, G., & Weitschek, E. (2017). A novel method and software for automatically classifying Alzheimer's disease patients by magnetic resonance imaging analysis. *Computer methods and programs in biomedicine*, 143, 89-95.
- [11] Yagis, E., Citi, L., Diciotti, S., Marzi, C., Atnafu, S. W., & De Herrera, A. G. S. (2020, July). 3d convolutional neural networks for diagnosis of alzheimer's disease via structural mri. In 2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS) (pp. 65-70). IEEE.
- [12] Çınar, K., & İskefiyeli, M. (2023). Endüstriyel Kontrol Sistemlerinde Yenilikçi Anomali Tespit Sistemlerinin İncelenmesi. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(1), 34-46.
- [13] Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A convnet for the 2020s. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11976-11986).
- [14] Farooq, A., Anwar, S., Awais, M., & Rehman, S. (2017, October). A deep CNN based multi-class classification of Alzheimer's disease using MRI. In *2017 IEEE International Conference on Imaging systems and techniques (IST)* (pp. 1-6). IEEE.

- [15] Fouladi, S., Safaei, A. A., Arshad, N. I., Ebadi, M. J., & Ahmadian, A. (2022). The use of artificial neural networks to diagnose Alzheimer's disease from brain images. *Multimedia Tools and Applications*, 81(26), 37681-37721.
- [16] Sisodia, P. S., Ameta, G. K., Kumar, Y., & Chaplot, N. (2023). A Review of Deep Transfer Learning Approaches for Class-Wise Prediction of Alzheimer's Disease Using MRI Images. *Archives of Computational Methods in Engineering*, 1-21.
- [17] Qiu, S., Joshi, P. S., Miller, M. I., Xue, C., Zhou, X., Karjadi, C., ... & Kolachalama, V. B. (2020). Development and validation of an interpretable deep learning framework for Alzheimer's disease classification. *Brain*, 143(6), 1920-1933.
- [18] Ramzan, F., Khan, M. U. G., Rehmat, A., Iqbal, S., Saba, T., Rehman, A., & Mehmood, Z. (2020). A deep learning approach for automated diagnosis and multi-class classification of Alzheimer's disease stages using resting-state fMRI and residual neural networks. *Journal of medical systems*, 44, 1-16.
- [19] Buvaneswari, P. R., & Gayathri, R. (2021). Deep learning-based segmentation in classification of Alzheimer's disease. *Arabian Journal for Science and Engineering*, 46, 5373-5383.
- [20] Feyzioğlu, A. A Cross Sectional Analysis of Patients Followed in Dementia Clinic. *Comprehensive Medicine*, 12(3), 276-279.
- [21] Barbarino, P. (t.y.). World Alzheimer Report 2021 Journey through the diagnosis of dementia.
- [22] Bourin, M. How to Diagnose an Alzheimer Disease?.
- [23] Jonsson, T., Atwal, J. K., Steinberg, S., Snaedal, J., Jonsson, P. V., Bjornsson, S., ... & Stefansson, K. (2012). A mutation in APP protects against Alzheimer's disease and age-related cognitive decline. *Nature*, 488(7409), 96-99.
- [24] Selkoe, D. J., & Hardy, J. (2016). The amyloid hypothesis of Alzheimer's disease at 25 years. *EMBO molecular medicine*, 8(6), 595-608.
- [25] Fidziańska, A., & Glinka, Z. (2006). Rimmed vacuoles with beta-amyloid and tau protein deposits in the muscle of children with hereditary myopathy. *Acta Neuropathologica*, 112(2), 185-193. <https://doi.org/10.1007/s00401-006-0079-3>
- [26] Chiang, H. S., & Pao, S. C. (2016). An EEG-based fuzzy probability model for early diagnosis of Alzheimer's disease. *Journal of medical systems*, 40, 1-9.
- [27] Borroni, B., DiLuca, M., Cattabeni, F., & Padovani, A. (2004). Advance on the diagnostic potential of biological markers in the early detection of Alzheimer disease. *Neuroscience Research Communications*, 35(3), 232-245.
- [28] Alzheimer's Facts and Figures Report | Alzheimer's Association. (t.y.). Geliş tarihi 01 Haziran 2023, gönderen <https://www.alz.org/alzheimers-dementia/facts-figures>
- [29] Knopman, D. S., & Petersen, R. C. (2014, October). Mild cognitive impairment and mild dementia: a clinical perspective. In *Mayo Clinic Proceedings* (Vol. 89, No. 10, pp. 1452-1459). Elsevier.
- [30] Planche, V., Manjon, J. V., Mansencal, B., Lanuza, E., Tourdias, T., Catheline, G., & Coupé, P. (2022). Structural progression of Alzheimer's disease over decades: the MRI staging scheme. *Brain Communications*, 4(3), fcac109.
- [31] "Alzheimer Disease International Conference 2022". Erişim 26 Aralık 2022. <https://www.alzint.org/what-we-do/adi-conference/adi-conference-2022/>.
- [32] Lightman, N., & Good Gingrich, L. (2018). Measuring economic exclusion for racialized minorities, immigrants and women in Canada: Results from 2000 and 2010. *Journal of Poverty*, 22(5), 398-420.

- [33] Porsteinsson, A. P., Isaacson, R. S., Knox, S., Sabbagh, M. N., & Rubino, I. (2021). Diagnosis of early Alzheimer's disease: clinical practice in 2021. *The journal of prevention of Alzheimer's disease*, 8, 371-386.
- [34] Alzheimer's Facts and Figures Report | Alzheimer's Association. (t.y.). Geliş tarihi 01 Haziran 2023, gönderen <https://www.alz.org/alzheimers-dementia/facts-figures>
- [35] Gunasekaran, T. I., & Ohn, T. (2015). MicroRNAs as Novel Biomarkers for the Diagnosis of Alzheimer's Disease and Modern Advancements in the Treatment. *Biomedical Science Letters*, 21(1), 1-8.
- [36] Alheimers Disease Interneational - Conference 2022. (t.y.). Geliş tarihi 02 Mayıs 2023, gönderen <https://www.alzint.org/what-we-do/adi-conference/adi-conference-2022/>
- [37] Doğan, F., & Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- [38] Yüzgeç, E., & Talo, M. Alzheimer ve Parkinson Hastalıklarının Derin Öğrenme Teknikleri Kullanılarak Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2), 473-482.
- [39] AlSaeed, D., & Omar, S. F. (2022). Brain MRI analysis for Alzheimer's disease diagnosis using CNN-based feature extraction and machine learning. *Sensors*, 22(8), 2911
- [40] Sethuraman, S. K., Malaiyappan, N., Ramalingam, R., Basheer, S., Rashid, M., & Ahmad, N. (2023). Predicting Alzheimer's Disease Using Deep Neuro-Functional Networks with Resting-State fMRI. *Electronics*, 12(4), 1031.
- [41] Aydos, U., Akdemir, Ü. Ö., Özçelik, M., Gülbahar, S., Karabacak, N. İ., & Atay, L. Ö. (2017). Gazi Üniversitesi Tıp Fakültesi, Nükleer Tıp Anabilim Dalı 2015 Aralık-2017 Şubat PET/MRG'nin Kullanımına Yönelik Deneyimimiz: İlk 1000 Olgudan Klinik Örnekler. *Nükleer Tıp Seminerleri*, 3(1).
- [42] Cahan, A., & Cimino, J. J. (2017). A learning health care system using computer-aided diagnosis. *Journal of medical Internet research*, 19(3), e54.
- [43] Cañal, J. P. A. (2010). CT Scan: Is It Really Safe?. *Acta Medica Philippina*, 44(3).
- [44] Petrik, V., Apok, V., Britton, J. A., Bell, B. A., & Papadopoulos, M. C. (2006). Godfrey Hounsfield and the dawn of computed tomography. *Neurosurgery*, 58(4), 780-787.
- [45] Bostrom, N., & Yudkowsky, E. (2018). The ethics of artificial intelligence. In *Artificial intelligence safety and security* (pp. 57-69). Chapman and Hall/CRC.
- [46] Wang, P. (2019). On defining artificial intelligence. *Journal of Artificial General Intelligence*, 10(2), 1-37.
- [47] Competition, F. A. L. P. (1992). Can Machines Think?. *AI Magazine*, 13(2).
- [48] Luxton, D. D. (2014). Artificial intelligence in psychological practice: Current and future applications and implications. *Professional Psychology: Research and Practice*, 45(5), 332.
- [49] Brynjolfsson, E., & McAfee, A. N. D. R. E. W. (2017). Artificial intelligence, for real. *Harvard business review*, 1, 1-31.
- [50] Altunok, C., & Ünver, M. (2020). Medikal Endüstride Yapay Zeka ve Uzman Sistemlerin Sürekli İyileştirmeye Etkisi. *Academic Perspective Procedia*, 3(1), 482-490. <https://doi.org/10.33793/acperpro.03.01.9>
- [51] Beamish, J. (2020). Success Factors in Artificial Intelligence (AI)-Focus on Use of AI in Journalism. Unpublished Master's thesis,(UNIVERSITY OF APPLIED SCIENCES, Business Administration (MBA), 4-67.
- [52] Saibene, A., Assale, M., & Giltri, M. (2021). Expert systems: Definitions, advantages and issues in medical field applications. *Expert Systems with Applications*, 177, 114900.
- [53] Kayode, A. A. (2012). An Integrated Knowledge Base System Architecture for Histopathological Diagnosis of Breast Diseases.

- [54] Place, J.F., Truhaus, A., Ozawa, K., Pardue, H., Schnipelsky, P., (1995). Use of artificial intelligence in analytical systems for the clinical laboratory, *Automatic Chemistry*, Cilt:17, Sayı: 1, pp.1-15
- [55] Kumar, S., Jain, S., & Sharma, H. (2018). Genetic algorithms. In *Advances in swarm intelligence for optimizing problems in computer science* (pp. 27-52). Chapman and Hall/CRC.
- [56] Atalay, M., & Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ Ve Makine Öğrenmesi Uygulamaları - Artificial Intelligence and Machine Learning Applications in Big Data Analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 155-172. <https://doi.org/10.20875/makusobed.309727>
- [57] Bahadır, E. (2017). Bulanık Mantık Yaklaşımının Eğitim Çalışmalarında Kullanılmasının Alan Yazın Işığında Değerlendirilmesi. *Uluslararası Sosyal ve Eğitim Bilimleri Dergisi*, 4(7), 28-42.
- [58] Teri, S. S., & Musliman, I. A. (2019). Machine learning in big lidar data: A review. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 641-644.
- [59] Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1), 3-24.
- [60] Bunker, R. P., & Thabtah, F. (2019). A machine learning framework for sport result prediction. *Applied computing and informatics*, 15(1), 27-33.
- [61] Dridi, S. (2021). Supervised Learning-A Systematic Literature Review.
- [62] Denetimsiz öğrenme (Unsupervised learning) | yavuz blog. (t.y.). Geliş tarihi 02 Haziran 2023, gönderen <https://yavuz.github.io/denetimsiz-ogrenme/>
- [63] Figure: Typical Structure of a Nerve Cell—MSD Manual Consumer Version. (t.y.). Geliş tarihi 02 Haziran 2023, gönderen <https://www.msdmanuals.com/home/multimedia/figure/typical-structure-of-a-nerve-cell>
- [64] Kanat, E. (2020). Determination of Optimum Artificial Neural Network in the Stock Market. *Turkish Studies-Economics, Finance, Politics*, 15(1), 239-252.
- [65] Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5), 717-727.
- [66] Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- [67] Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- [68] Dongare, A. D., Kharde, R. R., & Kachare, A. D. (2012). Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1), 189-194.
- [69] Gorunescu, F., & Belciug, S. (2016). Boosting backpropagation algorithm by stimulus-sampling: Application in computer-aided medical diagnosis. *Journal of biomedical informatics*, 63, 74-81.
- [70] Deka, B., Ha Nguyen, L., Amiri, S., & Goulet, J. A. (2022). The Gaussian multiplicative approximation for state-space models. *Structural Control and Health Monitoring*, 29(3), e2904.
- [71] Foh, C. H., & Lee, B. S. (2004, June). A closed form network connectivity formula one-dimensional MANETs. In *2004 IEEE International Conference on Communications (IEEE Cat. No. 04CH37577)* (Vol. 6, pp. 3739-3742). IEEE.
- [72] Razzak, M. I., Naz, S., & Zaib, A. (2018). Deep learning for medical image processing: Overview, challenges and the future. *Classification in BioApps: Automation of Decision Making*, 323-350.
- [73] Kim, K. G. (2016). Book review: Deep learning. *Healthcare informatics research*, 22(4), 351-354.

- [74] Bingol, K., Akan, A. E., Örmecioglu, H. T., & Er, A. (2020). Artificial intelligence applications in earthquake resistant architectural design: Determination of irregular structural systems with deep learning and ImageAI method.
- [75] Bingol, K., Akan, A. E., Örmecioglu, H. T., & Er, A. (2020). Artificial intelligence applications in earthquake resistant architectural design: Determination of irregular structural systems with deep learning and ImageAI method.
- [76] Umut, Kaya., Yılmaz, A., & Dikmen, Y. (2019). Sağlık alanında kullanılan derin öğrenme yöntemleri. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 792-808.
- [77] Keleş, A. (2018). Derin Öğrenme Ve Sağlık Alanındaki Uygulamaları. *Electronic Turkish Studies*, 13(21).
- [78] Talo, M. (2019). Meme Kanseri Histopatolojik Görüntülerinin Konvolüsyonel Sinir Ağları ile Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(2), 391-398.
- [79] CS 230—Evrişimli Sinir Ağları El Kitabı. (t.y.). Geliş tarihi 02 Haziran 2023, gönderen <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks>
- [80] Ferracuti, N., Norscini, C., Frontoni, E., Gabellini, P., Paolanti, M., & Placidi, V. (2019). A business application of RTLS technology in Intelligent Retail Environment: Defining the shopper's preferred path and its segmentation. *Journal of Retailing and Consumer Services*, 47, 184-194.
- [81] Amidi, A., & Amidi, S. (2018). VIP Cheatsheet: Convolutional Neural Networks. *Deep Learn*.
- [82] Eker, A. G., & Nevcihan, Duru (2021). Medikal görüntü işlemede derin öğrenme uygulamaları. *Acta Infologica*, 5(2), 459-474.
- [83] Bejani, M. M., & Ghatee, M. (2021). A systematic review on overfitting control in shallow and deep neural networks. *Artificial Intelligence Review*, 54(8), 6391-6438.
- [84] Jabbar, H., & Khan, R. Z. (2015). Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Computer Science, Communication and Instrumentation Devices*, 70.
- [85] Tokmak, M., & Kiraç, A. (2021). Classification of Some Species of Shrikes Family by Convolutional Neural Networks. *Bilge International Journal of Science and Technology Research*. <https://doi.org/10.30516/bilgesci.886291>
- [86] Öğrenme Aktarımı/Transfer Learning | by Nova Research Lab. | novaresearchlab | Medium. (t.y.). Geliş tarihi 02 Haziran 2023, gönderen <https://medium.com/novaresearchlab/%C3%B6%C4%9Frenme-aktar%C4%B1m%C4%B1-transfer-learning-c0b8126965c4>
- [87] Marcus, Daniel S., Anthony F. Fotenos, John G. Csernansky, John C. Morris, ve Randy L. Buckner. "Open Access Series of Imaging Studies: Longitudinal MRI Data in Nondemented and Demented Older Adults". *Journal of Cognitive Neuroscience* 22, sy 12 (01 Aralık 2010): 2677-84. <https://doi.org/10.1162/jocn.2009.21407>
- [88] Alzheimer Hastalığı—Doç.Dr. Kenan KIBICI. (t.y.). Geliş tarihi 02 Haziran 2023, gönderen <https://www.kenankibici.com/hastaliklar/beyin-hastaliklari/alzheimer-hastaligi>
- [89] LaMontagne, P. J., Benzinger, T. L., Morris, J. C., Keefe, S., Hornbeck, R., Xiong, C., ... & Marcus, D. (2019). OASIS-3: longitudinal neuroimaging, clinical, and cognitive dataset for normal aging and Alzheimer disease. *MedRxiv*, 2019-12.
- [90] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). IDAP | International Artificial Intelligence and Data Processing Symposium. (t.y.). Geliş tarihi 26 Aralık 2022, gönderen <http://idap.inonu.edu.tr/>

- [91] Masilamani, G. K., & Valli, R. (2021, July). Art Classification with Pytorch Using Transfer Learning. In 2021 International Conference on System, Computation, Automation and Networking (ICSCAN) (pp. 1-5). IEEE.
- [92] Junaidi, A., Lasama, J., Adhinata, F. D., & Iskandar, A. R. (2021, July). Image Classification for Egg Incubator using Transfer Learning of VGG16 and VGG19. In 2021 IEEE International Conference on Communication, Networks and Satellite (COMNETSAT) (pp. 324-328). IEEE.
- [93] Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., & Serhani, M. A. (2021). Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures. *Sensors*, 21(5), 1688.
- [94] Zhao, T., Liu, P., Lu, X., & Lee, K. (2022). OmDet: Language-Aware Object Detection with Large-scale Vision-Language Multi-dataset Pre-training. arXiv preprint arXiv:2209.05946.
- [95] Singh, N. (2020, Kasım 13). Paper Explained- Vision Transformers (Bye Bye Convolutions). Analytics Vidhya. <https://medium.com/analytics-vidhya/vision-transformers-bye-bye-convolutions-e929d022e4ab>
- [96] Sharma, A., & Muttoo, S. K. (2018, October). Spatial image steganalysis based on resnext. In 2018 IEEE 18th International Conference on Communication Technology (ICCT) (pp. 1213-1216). IEEE.
- [97] Tan, M., & Le, Q. V. (2019). Mixconv: Mixed depthwise convolutional kernels. arXiv preprint arXiv:1907.09595.
- [98] Mohanty, N., Pradhan, M., Reddy, A. V., Kumar, S., & Alkhayyat, A. (2022). Integrated Design of Optimized Weighted Deep Feature Fusion Strategies for Skin Lesion Image Classification. *Cancers*, 14(22), 5716.
- [99] Dinga, R., Penninx, B. W., Veltman, D. J., Schmaal, L., & Marquand, A. F. (2019). Beyond accuracy: measures for assessing machine learning models, pitfalls and guidelines. *BioRxiv*, 743138.
- [100] Chen, P. Y., & Soo, V. W. (2018, June). Humor recognition using deep learning. In Proceedings of the 2018 conference of the north american chapter of the association for computational linguistics: Human language technologies, volume 2 (short papers) (pp. 113-117).

ÖZGEÇMİŞ

Esra YÜZGEÇ

ÖZGEÇMİŞ

ÖZGEÇMİŞ

ÖZGEÇMİŞ

ARAŞTIRMA DENEYİMİ

- ✓ Derin Öğrenme
- ✓ Görüntü İşleme
- ✓ Sağlıkta Yapay Zeka

AKADEMİK FAALİYETLER

Makaleler:

- [1] Talo, M., Yüzgeç, E., Ergün, A. C., Yıldırım, Ö., Aydın, G., & Kaplan, M. (2021). Hidrosefali Interdisipliner Yaklaşım. Hipokrat Yayınevi.
- [2] Yüzgeç, E., & Talo, M. (2023). Alzheimer ve Parkinson Hastalıklarının Derin Öğrenme Teknikleri Kullanılarak Sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 35(2), 473-482.

Bildiriler:

- [1] Yüzgeç, E., & Talo, M. (2022). 1. IDAP | International Artificial Intelligence and Data Processing Symposium. In Derin Öğrenme Teknikleri Kullanılarak Alzheimer Hastalığı Aşamalarının Sınıflandırılması (pp. 64-68).