



**MANYETİK REZONANS GÖRÜNTÜLEME
KULLANILARAK 2B-ESA İLE ALZAYMIR
HASTALIĞININ SINIFLANDIRILMASI**

**2023
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

Rabeea Salim Fadaam FADAAM

**Tez Danışmanı
Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

**MANYETİK REZONANS GÖRÜNTÜLEME KULLANILARAK 2B-ESA İLE
ALZAYMIR HASTALIĞININ SINIFLANDIRILMASI**

Rabeea Salim Fadaam FADAAM

Tez Danışmanı

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY

T.C.

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalında

Yüksek Lisans Tezi

Olarak Hazırlanmıştır

KARABÜK

Aralık 2023

Rabeea Salim Fadaam FADAAM tarafından hazırlanan “MANYETİK REZONANS GÖRÜNTÜLEME KULLANILARAK 2B ESA İLE ALZAYMIR HASTALIĞININ SINIFLANDIRILMASI” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 04 /12/ 2023

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Dr. Öğr. Üyesi Emrah ÖZKAYNAK (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Abdulkadir TAŞDELEN (AYBÜ)

.....

Üye : Dr. Öğr. Üyesi Nesrin AYDIN ATASOY (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile Yüksek Lisans derecesini onamıştır.

Doç. Dr. Zeynep ÖZCAN

.....

Lisansüstü Eğitim Enstitüsü Müdürü



“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Rabeea Salim Fadaam FADAAM

ÖZET

Yüksek Lisans Tezi

MANYETİK REZONANS GÖRÜNTÜLEME KULLANILARAK 2B-ESA İLE ALZAYMIR HASTALIĞININ SINIFLANDIRILMASI

Rabeea Salim Fadaam FADAAM

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Öğr. Üyesi, Dr. Nesrin AYDIN ATASOY

Aralık 2023, 37 sayfa

Alzaymır hastalığı (AH), bilişsel işlevi ve hafızayı etkileyen nörodejeneratif bir hastalıktır. Özellikle yaşlılarda bunamanın en yaygın nedenidir ve hem hastalar hem de aileleri üzerinde önemli bir etkiye sahiptir. AH'nın erken teşhisi, sağlığın korunması için önemlidir. Geleneksel yöntemler kullanarak hastalığı doğru bir şekilde teşhis etmek ve sınıflandırmak zor olabilir. Bu nedenle, AH'nın sınıflandırılması için umut vaat eden bir yaklaşım olan derin öğrenme modellerinden İki Boyutlu (2B) Evrişimli Sinir Ağları (ESA) kullanılabilir. Bu model, tıbbi görüntülerden özellikleri otomatik olarak öğrenebilir ve sınıflandırabilir. Bu çalışmada, manyetik rezonans görüntüleme (MRG) veri seti kullanılarak AH'nı sınıflandırmak için amacıyla 2B ESA modeli önerilmektedir. Genel anlamda, AH'nın sınıflandırılmasında 2B ESA'lerin kullanımı, tanıdaki doğruluğu ve verimliliği artırma konusunda büyük bir potansiyele sahiptir. Bu modellerin klinik uygulamadaki yeteneklerini ve sınırlılıklarını tam anlamıyla kavramak için daha

fazla arařtırmaya ihtiya duyulmaktadır. nerilen model %90'ın zerinde bir doęrulukla AH olan hastaları sınıflandırabilmiřtir Geleneksel yntemlere gre nemli lde daha iyi performans gstermiřtir.

Anahtar Szckler: 2B Evriřimli Sinir Aęları, Alzaymır hastalıęı sınıflandırılması,
Derin ęrenme.

Bilim Kodu : 92432



ABSTRACT

M. Sc. Thesis

CLASSIFICATION OF ALZHEIMER’S DISEASE USING 2DCNN TECHNOLOGY USING MAGNETIC RESONANCE IMAGING

Rabeea Salim Fadaam FADAAM

Karabuk University

Institute of Graduate Programs

The Department of Computer Engineering

Thesis Advisor:

Assist. Prof. Dr. Nesrin AYDIN ATASOY

December 2023, 37 sayfa

Alzheimer’s disease (AD) is a neurodegenerative disorder that affects cognitive function and memory. It is the most common cause of dementia in the elderly and has a significant impact on both patients and their families. Early diagnosis of Alzheimer’s disease is important for health maintenance. Traditional methodologies employed in diagnosing and classifying this disease often encounter limitations in accuracy and efficacy. Therefore, utilizing Two-Dimensional (2D) Convolutional Neural Networks (CNNs) is more promising for classifying Alzheimer’s disease. This model can automatically learn and classify features from medical images. This study proposes a 2D CNN model to classify Alzheimer’s disease using a magnetic resonance imaging (MRI) dataset. Overall, utilizing Two-Dimensional (2D) Convolutional Neural Networks (CNNs) to classify Alzheimer’s disease has a great potential to increase diagnostic accuracy and efficiency. Further research is necessary to comprehensively understand the capabilities and limitations of these models in

clinical practice. The proposed model was able to classify AD patients with an accuracy exceeding 90%, significantly outperforming traditional methods.

Key Words : 2D-Convolutional Neural Networks, Alzheimer's Disease Classification, Deep Learning.

Science Code : 92432



TEŞEKKÜR

Öncelikle, yüce Rabbim'e yürüdüğüm bu yolda bana lütfettiği başarı için sonsuz şükürler olsun. Değerli Dr. Nesrin AYDIN ATASOY hocama gösterdiği rehberlik ve verdiği destekten ötürü teşekkürlerimi iletiyorum. Karabük Üniversitesi'nin sunduğu imkanlar ve kıymetli öğretim üyelerinin teşvikleri için minnettarım. Elde ettiğim bu başarıyı, annem ve babama (Allah rahmet eylesin) armağan ediyorum. Bu süreçte bana destek olan eşime, kardeşlerime ve arkadaşlarıma derin şükranlarımı sunuyorum. Tezimi, bize fırsatlar sunan ana vatanım Irak'a ve misafirperver Türkiye'ye ithaf ediyorum. Teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
KISALTMALAR	xiii
BÖLÜM 1	1
GİRİŞ	1
1.1. GENEL BAKIŞ	1
1.2. ARAŞTIRMA PROBLEMİ	3
1.3. ARAŞTIRMANIN ÖNEMİ	4
BÖLÜM 2	5
LİTERATÜR ÇALIŞMASI.....	5
BÖLÜM 3	9
ÖNERİLEN MODEL.....	9
3.1. ESA	9
3.1.1. ESA Mimarisi	10
3.1.2. ESA İçin Temel Kavramlar	11
3.2. ESA OLUŞTURULMASI.....	13
3.2.1. Evrişimli Katman.....	14
3.2.2. Havuzlama Katmanı	15
3.2.3. Maksimum Havuzlama	15
3.2.4. ReLU Katmanı.....	16
3.2.5. Kayıp Katmanı.....	17

	<u>Sayfa</u>
3.2.6. Softmax Fonksiyonu	17
3.3. DEĞERLENDİRME METRİKLERİ	18
3.4. K- KATLAMALI ÇAPRAZ DOĞRULAMA	19
 BÖLÜM 4	 21
TASARLANAN MODELİN ÖZELLİKLERİ	21
4.1. VERİ SETİ	21
4.2. YÖNTEM ÖZETİ	23
4.3. VERİ YÜKLEME	24
4.4. KULLANILAN TEKNOLOJİLER.....	25
4.4.1. Tensorflow	25
4.4.2. Keras	26
4.4.3. Numpy Kütüphanesi	26
4.4.4. Pandas Veri İşleme Kütüphanesi	27
 BÖLÜM 5	 28
SONUÇLAR	28
5.1. TARTIŞMA.....	30
 BÖLÜM 6	 31
SONUÇ VE GELECEK ÇALIŞMALAR.....	31
 KAYNAKLAR	 32
 ÖZGEÇMİŞ	 37

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1 . Alzaymır hastalığı olan beyin görüntüsü	3
Şekil 3.1. önerilen ESA modeli diyagramı.....	10
Şekil 3.2. Tam bağlantılı katmanlara sahip genel ESA.....	11
Şekil 3.3. Basit ESA katmanlarının genel bakışı	14
Şekil 3.4. ESA’da pooling katmanı ve softmax	18
Şekil 3.5. K katlamalı çapraz doğrulama (K-fold Cross Validation).....	20
Şekil 4.1. Tedavi öncesi beyin resimleri.	22
Şekil 4.2. Eğitim veri seti görüntü örnekleri.	23
Şekil 4.3. Eğitim veri seti görüntü örnekleri.	24
Şekil 4.4. Erken durdurma	25
Şekil 5.1. Çapraz doğrulama sonrası model doğruluğu ve kayıp grafiği.	29
Şekil 5.2. Çapraz doğrulama sonrası karmaşıklık matrisi.....	29

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1. AH' na dair makalelerin model performans karşılaştırması.	8
Çizelge 3.1. Önerilen ESA modeli	10
Çizelge 4.1. Veri Seti Görüntü Miktar.	21
Çizelge 5.1. Önerilen ESA modelin mimari detayları.	28
Çizelge 5.2. Önerdiğimiz modelin diğer modellerle karşılaştırılması.	30



KISALTMALAR

ESA	: Evriřimli Sinir Ađı
KDS	: Klinik Demans Sınıflandırması
GBÖ	: Global Bozulma Ölçeđi
MMDM	: Mini-Mental Durum Muayenesi
2B-ESA	: İki Boyutlu Evriřimli Sinir Ađı
USE	: Ulusal Sađlık Enstitüsü
MRG	: Manyetik Rezonans Görüntüleme
HBB	: Hafif Biliřsel Bozukluk
AH	: Alzaymır Hastalıđı
BT	: Bilgisayarlı Tomografi
DVM	: Destek Vektör Makinesi
DTG	: Difüzyon Tensor Görüntüleme
PSO	: Parçacık Sürü Optimizasyonu
GM	: Gri Madde
BM	: Beyaz Madde
AHNİ	: Alzaymır Hastalıđı Nörogörüntüleme İnisiyatifi

BÖLÜM 1

GİRİŞ

1.1. GENEL BAKIŞ

Alzaymır hastalığı (AH) hala 60 yaşın üzerindeki insanlar için birçok sağlık sorununa neden olan hastalıklardan biridir. Bu nedenle hastalığın teşhis edilmesinde kullanılan yöntem, hastalığın nedeni ve hastalığın nasıl ortaya çıktığı bilgisinin elde edilmsi için uzun süren araştırmalar olmuştur [1]. Teknolojik ilerleme ile, AH'nın yenilikçi ve nitelikli tespiti için bilgisayar destekli çözümler bulunmuştur. Yani, tespitite İki Boyutlu (2B) Evrişimli Sinir Ağları (ESA), derin öğrenmeye dayalı bir model olarak, iyi eğitilmiş yapay evrişimli sinir hücreleri kullanarak AH'nı tespit etmeyi sağlayan yenilikçi ve nitelikli bir yöntemdir. Bu yöntem, bilgi depolama ve bu hastalığın en doğru tıbbi muayenesini elde etmek için kullanılan yazılım stratejilerinin doğası aracılığıyla AH'nı tespit etmelerine olanak sağlayan nitelikli bir yöntemle birlikte çalışır [2]. AH olan hastaların görüntülerini yorumlayabilen ve teşhis edebilen bir programın üretiminde kullanılan yöntemin doğasında başarılı teşhis sonuçları elde etme bulunmaktadır. [3].


Derinlemesine bilimsel araştırmalar sayesinde, AH'nın doğru teşhisini elde etmek için takip edilen birçok teknik ve yazılım modeli bulunmaktadır. Bu yöntemler farklı ve değişken oranlarda başarılı sonuçlar elde etmektedir. AH hakkında iyi teşhis sonuçları elde etmek için kullanılan [4] algoritmalarda, bu oranlar %90'dan %97'ya kadar değişmektedir [5]. Bununla birlikte, AH'nın teşhisinde uzmanlaşmış tüm bu ağ algoritmaları arasında öne çıkan bir algoritma olan 2B-ESA adlı bir teknik bulunmaktadır. Bu algoritma, yukarıdaki oranları aşan % 99 gibi yüksek bir başarı oranına ulaşmıştır. 2B-ESA, 3D MRG görüntüler üzerinde hastalığın teşhisi için mükemmel sonuçlar ve etkinlik sağlamıştır. İlerleyen bölümlerde 2B-ESA teknolojisini kullanarak evrişimli sinir ağının yapısının, tasarımının ve işleyişinin

doğası hakkında en iyi olası resmi sunmak için özel bir yöntem ve tasarıma dayanan [6] model anlatılmaktadır.

Şekil 1.1’ de görüldüğü gibi AH, hastanın beyin ve zihinsel sağlığını etkileyen nörolojik bir hastalıktır çünkü bu hastalığı olan kişileri etkileyen belirtiler unutkanlık ve birçok şeyi hatırlayamamadır. Hatta hastalığın ilerleyen evrelerine gelindiğinde aile üyelerinin isimlerini unutma durumu ortaya çıkar. Bu hastalığın varlığını gösteren tıbbi teşhisler arasında beta-amiloitin görünümü yer alır, bu da bu hastaların sürekli bakıma ihtiyaç duyduklarını gösterir. AH 65 yaş ve üzeri hastalarda teşhis edilir, ancak gelişmiş ülkelerde bu oran 85 yaşındaki kişilerde %30’a kadar daha yüksektir ve tıbbi çalışmalar, AH’nın Amerika’da ölüm oranına göre altıncı sırada geldiğini ve her 65 saniyede bir kişinin AH veya bunama yaşadığını kanıtlamıştır [7].

AH, Çok Hafif Demanslı, Hafif Demanslı, Orta Derecede Demanslı, Demans Olmayan 4 patolojik seviyeye sınıflandırmak mümkündür. Hastalığın erken tanınması, hastalığın bir kişinin yaşamını olumsuz etkileyen aşamalara ilerlemesini azaltma nedeni olabilir. İnsan beynini büyük ölçüde etkileyen en yaygın faktörlerden biri ise beyin korteksinin küçülmesidir. Hastalığa sahip olan kişinin korteksi küçülürken, normal bir büzülme hipokampusta meydana gelir. Bu bölge, günlük yaşam aktivitelerini düşünme ve hatırlama yeteneği sağlar ve bu bölgedeki azalma, beyin korteksinin küçülmesine ve ventriküllerin genişlemesine yol açar [8].

Bu hastalığın teşhisi için birçok yöntem, detaylı bir tarih, fiziksel ve nörobiyolojik muayene, anket ve Neuropsikolojik Envanter ile fonksiyonel değerlendirme anketi gibi bilgileri içeren tam bir klinik teşhisi gerektirir. Klinik Demans Sınıflandırması (KDS) gibi Mini Mental Durum Muayenesi (MMDM) Ölçeği, Global Bozulma Ölçeği (GBÖ) ve Alzaymır Derneği Ulusal Enstitüsü tarafından AH’nın teşhisi için geliştirilen diğer birçok klinik değerlendirme kriteri kullanılır.



Şekil 1.1 . Alzaymır hastalığı olan beyin görüntüsü [45].

Bu teknikteki araştırmanın bir sorunu, doğru teşhisi elde etmek için zaman alıcı olması ve teşhis konusunda çok deneyim gerektirmesidir. Özellikle erken aşamalarda, yani manuel özellik önileme adımlarında ve bu denetimli yöntemlerle yapılan özellik çıkarma aşamalarında hata yapılabilir ve görüntüden düşük seviyeli özellik çıkarımı yapılabilir. Böylece en iyi performansı elde etmede başarısız olunabilir. Bununla birlikte, beyin MRG, derin evrişimli sinir ağlarının eğitildiği bilgilere dayanak oluşturabilen üç boyutlu bir görüntü hacmini temsil eder. Derin öğrenme teknolojisine dayanan 2B-ESA, 3D MRG görüntülerini giriş olarak alarak daha düzgün ve daha doğru arama sonuçları elde etmek için kullanılmaktadır [9].

1.2. ARAŞTIRMA PROBLEMİ

Bu çalışmada, 2B-ESA derin öğrenme teknolojisine dayanan AH'nı 3B MRG görüntüleri kullanarak sınıflandırılması gerçekleştirilmektedir. Farklı çalışmalarda olduğu gibi önce veri seti düzenlenecek ve model en iyi performans ile denenecektir [10].

Bilindiği gibi, AH tamamen spesifik bir tedaviye sahip olmayan hastalıklardan biridir. Çünkü nörodejeneratif bir hastalıktır. Bunama veya unutkanlık olarak bilinir. Bunama, belleği, düşüncüyü olumsuz etkileyen ve hasta davranışını etkileyen semptomları olan beyin hasarıyla ortaya çıkan hastalıklar için daha geniş bir terimdir.

Bu nedenle, AH'nı sınıflandırmak ve tespit etmek için bilateral ve çoklu kategoriler için bütün beyin MRG verilerinde boyutsallık azaltma yöntemleri ve çeşitlilikleri kullanılmıştır. Erken evre AH'nı sınıflandırmak için hibrit bir yaklaşım önerilmiş ve

bu yaklaşımın doğruluğu, MRG ve klinik verilerden oluşturulan hibritleşmiş karakteristik vektör kullanılarak iyileştirilmiştir.

Tüm MRG görüntülerinden çıkarılan özellikler ve 2B ESA, hastalığın en iyi teşhisini ve erken teşhisini bulmaya yönelik araştırma probleminin odak noktası olan birçok etkili teknikten biridir [11].

1.3. ARAŞTIRMANIN ÖNEMİ

AH, birçok insan için bir engel ve anormal bir sorun teşkil eden hastalıklardan biri olduğu göz önünde bulundurulduğunda, 65 yaş ve üzerindeki yaşları dikkate alarak, sağlık açısından bir engel oluşturur. AH, belirli beyin hasarlarından kaynaklanan bir işlev bozukluğudur ve şu anda bilinen bir tedavisi yoktur. Bununla birlikte, araştırmacılar yapay konvülsiyonel sinir ağları kullanarak hastalığı teşhis etme ve tanı koyma konusunda önemli ilerlemeler kaydetmiştir. Bu araştırma tezi, AH'nı doğru bir şekilde tanımlamak ve teşhis etmek için 2B-ESA teknolojisini kullanan bir algoritma geliştirmeye odaklanmaktadır. Tez, hem teorik hem de bilimsel yöntemleri kullanarak algoritmanın tasarımı ve testi hakkında detaylı bilgiler sunmaktadır.

BÖLÜM 2

LİTERATÜR ÇALIŞMASI

Literatür taramasında, AH'nın doğru bir şekilde tanımlanması ve teşhisi için 2B derin öğrenme teknolojisinin benimsenmesi olan ilgilenilen konuyla ilgili mevcut araştırma ve çalışmalara kapsamlı bir genel bakış sağlamaktır. Literatür taraması, bu alanda önceki araştırmacılar tarafından kullanılan temel bulguları, metodolojileri ve yaklaşımları özetlemeyi ve analiz etmeyi amaçlamaktadır.

AH, bellek kaybı ve bunama ile sonuçlanan bir nörolojik durumdur. Belleği, düşünceyi ve davranışları olumsuz etkileyebilen beyin hasarıyla ilişkili bir dizi hastalığı tanımlamak için kullanılan bir terimdir. Bu hastalık, beyinde hasara neden olur ve bireyler üzerinde sürekli bir etkiye sahiptir [12].

Devam eden araştırmalara rağmen, AH için şu anda bilinen bir tedavi yoktur ve çoğu insan hastalığın teşhisi 65-70 yaşından sonra konulmaktadır. Alzaymır hastalarının teşhisi için algoritma geliştirme sürecinde derin öğrenme önemli bir araç haline gelmiştir ve hastalığın HBB'den AH'ye seviye değişikliklerini BT ve MRG taramalarıyla tespit etmektedir. Alzaymır teşhisinde önemli bir faktör, hastanın semptomlarını iletebilme becerisidir ve ayrıca aile üyelerinin veya arkadaşların, bu semptomların hastanın günlük yaşamına olan etkilerine dair gözlemleri de dikkate alınır [13].

AH'nın teşhisi, bir bireyin bellek ve bilişsel yeteneklerini değerlendiren testler içerir, ancak bazı testler atlanabilir. AH'nın teşhisi genellikle ancak ölüm sonrası beyinde yapılan mikroskopik incelemeyle kesinleşir ve hastalığın en önemli özelliklerini ortaya koyabilir. Günümüzde doktorlar ve araştırmacılar, hastalığın varlığını gösteren biyobelirteçler kullanarak AH'nı yaşayan hastalarda daha kesin bir şekilde teşhis edebilmektedir. Örneğin, pozitron emisyon tomografisi gibi belirli türlerde

görüntüleme yöntemleri kullanılabilir veya plazma ve beyin omurilik sıvısında bulunan amiloid protein seviyeleri ölçülebilir. AH'nın belirgin semptomlara sahip olmasına rağmen, başlangıçta doğasını tam olarak anlamak zor olmuştur. Bununla birlikte, araştırmacılar ve bilim insanları hastalığın doğasını ve seviyesini belirlemek için araştırmalar yapmış ve testler geliştirmiştir. Bu testler, istemsiz reflekslerin değerlendirilmesi, kas kuvveti ve gerilimi, denge ve koordinasyon, görme ve işitme gibi unsurları içerebilir. Ayrıca, bellek ve diğer bilişsel becerilerin değerlendirilmesi için psikolojik bir inceleme de yapılabilir [14].

Uzun süreli nöropsikolojik incelemeler, aynı yaş ve eğitim arka planına sahip diğer bireylere kıyasla bir kişinin zihinsel fonksiyonları hakkında daha kapsamlı bilgi sağlayabilir. Bu taramalar, Alzaymır hastalarının semptomlarının teşhisi ve izlenmesi ile hastalığın ilerleyişi açısından faydalıdır. Ayrıca, inme, travma veya tümör gibi Alzaymır dışı durumlardan kaynaklanabilecek bilişsel fonksiyonları etkileyebilecek görsel anormallikleri de tespit edebilirler. Tıp merkezlerinde ve klinik denemelerde kullanılan yeni görüntüleme teknikleri, AH ile ilişkili belirli beyin değişikliklerini tespit etmede yardımcı olabilir.

Bu yöntemler MRG, BT, fluorodeoksiglukoz kullanarak pozitron emisyon tomografisi, amiloid kullanarak pozitron emisyon tomografisi ve tau proteinini kullanarak pozitron emisyon tomografisini içerir. Bu testler beyindeki nörofibriller demetlerin neden olduğu yükü ölçmek için kullanılır. Hızla ilerleyen demans, atipik özelliklere sahip demans veya erken başlangıçlı demans gibi belirli durumlarda, beyin omurilik sıvısında tau, amiloid ve beta proteinlerinin anormal seviyelerini ölçmek için ek testler kullanılabilir.

San Francisco'daki Gladstone Nörolojik Hastalıklar Enstitüsü'ndeki araştırmacılar, beyindeki bazı nöronların diğerlerine göre AH'na daha duyarlı olmasının nedenlerini aydınlatan yeni moleküler ipuçları keşfetmiştir [15].

Son çalışmalar bu yaklaşımı çeşitli şekillerde araştırmışlardır. Önerilen yöntem, derin öğrenme yoluyla doğru teşhis için görüntüleri segmente etme ve detaylandırma yeteneğine sahip benzersiz özelliklere sahip bir algoritma kullanmayı içermektedir.

Önerilen algoritma, araştırma programı aracılığıyla eğitilecektir ve AH'nın teşhisi araştırma hedefini gerçekleştirmek için kullanılacaktır [16]. Bilgisayar işlemleri ve veri bilimi alanında, derin öğrenme yöntemleri büyük önem taşır. Bu yöntemlerde, ham verileri besleyerek, insan zihninin bilgiyi nasıl işlediği gibi hiyerarşik bir şekilde veriyi öğrenen ve analiz eden bir ESA kullanılır.

Son yıllarda, araştırmacılar derin öğrenme tekniklerini hastaların tıbbi geçmişine dayanarak hastalıkları teşhis etmek için uygulamışlardır. Bu yöntemler, geleneksel tekniklere göre hastalık teşhisi ve sınıflandırmasında daha yüksek bir doğruluk göstermiş ve doğruluk oranları %84,4 ila %96 arasında değişmektedir.

ESA ve G-ESA gibi çok kategorili bir graf, AH verilerini sınıflandırmak için kullanılmış ve ağır çalışma dinamiklerini iki yöntem olan difüzyon tensör görüntüleme (DTG) ve G-ESA sınıflandırıcısı kullanarak eğitim ve doğrulama yoluyla geliştirmiştir. Bu yöntem, geleneksel destek vektör makinesine (DVM) göre daha iyi performans göstermektedir. Teknolojinin kapsamlı testlerden geçirilmesi ve geliştirilmesi sonucunda, bu derin öğrenme yöntemleri hastalıkları doğru bir şekilde teşhis etme ve sınıflandırma konusunda büyük potansiyele sahip olduğunu göstermektedir [17].

Ve Parçacık Sürü Optimizasyonu (PSO) yönteminin geliştirilmesi, beyin yapısındaki değişiklikleri analiz etme avantajları ve özelliklerin çıkarılmasında kullanılması, AH klinik muayenesi ile ilişkili olarak, çok kategorili bir sınıflandırmaya dayanan bir uygulama ile, o dönemde kullanılan tekniklerin en iyi performansının bilinmesi, konvolüsyonel sinir ağı teknolojisinin kullanılması için bir başlangıç noktası olarak belirlenmiştir. Sonra, manyetik rezonans görüntülerinde belirli bir doku bölgesinin tanımlanmasında yeni bir yöntem sunuldu. Bunun için 3D görüntülerden doku özelliklerinin çıkarılmasından sonra, bunlar farklı eksenlerde iki boyutlu kesitlere bölünür. İkinci adımda, Elastic Network Sorting ve DVM kullanarak sistem tarafından tespit yapısına yararlı olmayan özellikler çıkarılır ve silinen özellikler çoklu kategoriler kullanılarak analiz edilir ve kategorilere ayrılır, bunlar gerekli kabul edilmeyen özelliklerdir [18].

MRG'nın farklı bölümleri için dokusal ayrıştırma fikrine benzer şekilde kullanımı, OASIS veri setindeki görüntülerde olduğu gibi CSF, GM ve BM'yi ayırmak için kullanılan k-ortalama yöntemine benzerdir. Bu vektörler, her ayrıştırılmış bölgenin birleştirilerek tek bir vektör bölge oluşturma avantajına sahiptir, yani dokusal ve şekle dayalı özellikleri içerir ve bu özellikler DVM, KNN ve rastgele orman tarafından hastalık sınıflandırması için de kullanılmıştır. Genel olarak, 3D MRG verileri ve yüksek korelasyona sahip özelliklerin tam bilgisinin kullanımı, hesaplama maliyetini artırır ve çok kategorili sınıflandırmanın etkinliğini sınırlar. Ek olarak, sınıf dengesizliği, genel olarak teşhis çalışmalarında karşılaşılan bir sorundur.

Dengesiz 3D MRG verilerini kullanarak AH'nın farklı evrelerini teşhis etmek için 2B-ESA modeline dayanan akıllı ve doğru bir yöntem önerilmektedir. Bu çalışmanın katkıları, yüksek çözünürlüklü sonuçlar elde etme olasılığından dolayı gerçek durumunu üç kat artırır. 3D MRG verileri kullanmak yerine önce 3D görüntüleri 2B dilimlere dönüştürerek ESA modelinin yapısını basitleştirilmektedir

Önerilen 2B model, hesaplama yükünü azaltmak için umut verici özelliklere sahip dilimleri giriş olarak kullanır ve ardından hiçbir artırma kullanmadan dengesiz veri sorununu etkin bir şekilde ele alırız. Simülasyon çalışmaları, doğruluk, verimlilik ve yöntemin sağlamlığını değerlendirmek için AHNİ'nin bir alt seti ve MRG kullanarak bir veri seti üzerinde gerçekleştirilir ve sonra elde edilen sonuçlar önceki literatürle karşılaştırılarak elde edilen sonuçların doğruluğu belirlenir [19]. Aşağıdaki Tablo 2.1, AH hakkında yazılmış makalelerde kullanılan modellerin performansını göstermektedir

Çizelge 2.1. AH' na dair makalelerin model performans karşılaştırması.

Makale	Doğruluk	Veri seti	Model
[9]	75%	3D T1-weighted images from ADNI	CNN custom model
[8]	92%	OASIS dataset have 416 subjects	DenseNet-121
[7]	73%	OASIS dataset	CNN -RMSPProp algorithm
[41]	88 %	ADNI	CNN
[42]	85%	ADNI	Inceptionv3
[43]	95%	OASIS	CNN – Hybrid model

BÖLÜM 3


ÖNERİLEN MODEL

Derin öğrenme, verilerin derin temsillerini öğrenmeyi amaçlayan yapay zeka alanının bir dalıdır. AH'nın sınıflandırılmasını iyileştirmede derin öğrenmenin uygulanması oldukça önemlidir, çünkü bu teknoloji verileri analiz etmeye ve hastalığın desenlerini ve belirtilerini daha yüksek doğrulukla tanımaya yardımcı olabilir. AH'nın verilerini okumak ve sınıflandırmayı iyileştirmek için derin öğrenme uygulandığında, çok katmanlı derin sinir ağları verileri temsil etmek ve işlemek için kullanılır [20]. Bu derin sinir ağları mevcut verilerden öğrenir ve otomatik olarak AH'nın desenlerini ve belirleyici özelliklerini tespit etmek için analiz eder. Derin öğrenme, AH ile ilgili klinik verileri, beyin slayt görüntülerini de içeren büyük bir veri setinin toplanmasını gerektirir.

3.1. ESA

ESA, bilgisayarla görme ve görüntü sınıflandırma alanında devrim olmuştur. Nesne tanıma, görüntü bölümleme ve örüntü algılama gibi görevler için yaygın olarak kullanılırlar. Bu araştırma makalesinde, 224 x 224 piksel [21]. giriş boyutuna sahip görüntüleri işlemek için özel olarak tasarlanmış, görüntü sınıflandırması için bir ESA modeli öneriyoruz [22].

3.1.1. ESA Mimarisi



Şekil 3.1. önerilen ESA modeli diyagramı.


Önerdiğimiz ESA modeli, sıralı bir şekilde düzenlenmiş birkaç katmandan oluşur. Giriş katmanı, 224 x 224 piksel boyutunda olan görüntüleri alır. Modelin her bir katmanın detayları mimari detayları Şekil 3.1 ve Çizelge 3.1’de görülmektedir.

Çizelge 3.1. Önerilen ESA modeli

Katman (tip)	Çıktı Şekli	Parametreler
conv2d (Conv2D)	(None, 224, 224, 16)	448
conv2d_1 (Conv2D)	(None, 224, 224, 16)	2320
max_pooling2d (MaxPooling2D)	(None, 112, 112, 16)	0
sequential (Sequential)	(None, 56, 56, 32)	2160
sequential_1 (Sequential)	sequential_1 (Sequential)	7392
sequential_2 (Sequential)	(None, 14, 14, 128)	27072
dropout (Dropout)	dropout (Dropout)	0
sequential_3 (Sequential)	(None, 7, 7, 256)	103296
dropout_1 (Dropout)	(None, 7, 7, 256)	0
flatten (Flatten)	(None, 12544)	0
sequential_4 (Sequential)	(None, 512)	6425088
sequential_5 (Sequential)	(None, 128)	66176
sequential_6 (Sequential)	(None, 64)	8512
dense_3 (Dense)	(None, 4)	260
Total params 6,642,724		
Trainable params: 6,640,356		
Non-trainable params: 2,368		

3.1.2. ESA İçin Temel Kavramlar

ESA, özellikle görüntü ve video gibi görsel verileri işlemek ve analiz etmek için tasarlanmış bir yapay sinir ağı türüdür [23]. ESA, beyindeki görsel korteksin yapısı ve işlevine dayanır ve hiyerarşik bir şekilde birbirine bağlı çok katmanlı sinir hücrelerinden oluşur. Filtreleme katmanının çıktısına özellik haritası denir ve bu, yalnızca en ilgili ve önemli özellikleri içeren girdi verisinin bir temsilidir. Bir ESA bir sonraki katmanı genellikle bir havuzlama katmanıdır [24].



Şekil 3.2. Tam bağlantılı katmanlara sahip genel ESA [46].

Konvolüsyonel ve havuzlama katmanlarından sonra, bir ESA genellikle bir veya daha fazla tam bağlantılı katmana sahiptir. Bu katmanlar, geleneksel yapay sinir ağındaki katmanlara benzerdir. Bu katmanlar, özellik haritasına non-lineer bir dönüşüm uygular ve girdi veriyi birkaç önceden tanımlanmış kategori arasında sınıflandırmak veya sürekli bir çıktı değeri oluşturmak için kullanılır. Özetle, ESA'lar, görsel verileri işlemek ve analiz etmek için tasarlanmış bir tür yapay sinir ağıdır. Hiyerarşik bir şekilde birbirine bağlı olan çok katmanlı sinir hücrelerinden oluşurlar ve girdi veri üzerinde matematiksel işlemler yaparak özelliklerin çıkarılması ve analizi gerçekleştirirler. ESA'lar, görüntü sınıflandırma, nesne

algılama ve segmentasyon gibi bilgisayar görüşü görevlerinde yaygın olarak kullanılmaktadır [25].

2B ESA nın birincil işlevi, görseller veya 2B çizimler gibi iki boyutlu verilerden anlamlı bilgileri işlemek ve çıkartmaktır. Aşağıda 2B ESA'nın gerçekleştirdiği ana görevlerin ayrıntılı açıklanmıştır :


- **Özellik Çıkartma:** 2B ESA'nın ana görevlerinden biri özellik çıkartmadır. Bu, giriş görüntüsünü veya veriyi küçük öğrenilebilir filtreler veya çekirdekler ile taramaktadır, her konumda matematiksel işlemler (evrişimler) gerçekleştirmek şeklinde meydana gelir. Bu süreç, filtrelenmiş görselleri veya özellik haritalarını üretmektedir . Bu özellik haritaları, giriş verisindeki farklı özellikleri ve desenleri, örneğin kenarları, dokuları ve şekilleri temsil etmektedir.
- **Hiyerarşik Özellik Öğrenme:** 2B ESA'lar özelliklerin hiyerarşik temsillerini otomatik olarak öğrenirler. Kenarlar gibi basit özelliklerle başlarlar ve daha kompleks özellikler ve desenlere kademeli olarak ulaşırlar. Bu hiyerarşik öğrenme, ağırlıklı verilerdeki hem düşük seviyeli hem de yüksek seviyeli özellikleri algılamasını sağlar.
- **Mekansal Değişmezlik:** ESA'lar, bir resmin farklı bölümlerinde , tam mekansal konumlarına bakılmaksızın desenleri ve özellikleri tanıma yeteneğine sahiptirler. Bu mekansal değişmezlik, nesnelerin bir resimde çeşitli konumlarda görünebileceği görüntü tanıma gibi görevler için kritiktir.
- **Boyut Azaltma:** Havuzlama katmanları, genellikle evrişimli katmanlarla birlikte kullanılır, özellik haritalarının mekansal boyutlarını azaltırken temel bilgileri korur. Bu, hesaplamalı karmaşıklığı azaltır ve ağı girişteki varyasyonlara karşı daha dayanıklı hale getirir.
- **Sınıflandırma ve Tanıma:** ESA'lar, bir görüntünün belirli bir nesneyi veya kategoriyi içerip içermediğini belirlemek gibi sınıflandırma görevleri için kullanılabilir. Aynı zamanda nesne tespitine de uygulanabilir, burada ağı sadece nesneleri sınıflandırmakla kalmaz, aynı zamanda onları bir resim içinde bulur ve çerçeve içine alır.

- **Özellik Görselleştirme:** Araştırmacılar ve analistler, bir 2B ESA'nin eğitilmiş özellik haritalarını, ağı ne öğrendiğine dair iç görüler kazanmak için görselleştirebilirler. Bu, bir resmin hangi kısımlarının belirli bir sınıflandırma veya karara katkıda bulunduğunu belirlemeye yardımcı olabilir.
- **Transfer Öğrenme:** ImageNet gibi büyük veri kümelerinde eğitilmiş ön eğitilmiş 2B ESA modelleri, belirli görevler için ince ayar yapılabilir. Bu transfer öğrenme yaklaşımı, bir alandaki (örneğin, genel resim tanıma) bilginin diğer bir alandaki (örneğin, tıbbi görüntü analizi) için kullanılmasını sağlar.

Özetle, bir 2B ESA'nin birincil işi, görseller üzerindeki güçlü bir odaklama, iki boyutlu verilerdeki desenleri ve özellikleri analiz etme, tanıma ve sınıflandırmaktır. Bu ağlar, bilgisayar görüşü görevlerinde, görüntü sınıflandırma, nesne tespiti, yüz tanıma, hastalık tespiti ve daha fazlası da dahil olmak üzere yaygın olarak kullanılmaktadır. Ayrıca, yapılandırılmış çizim verilerinin yaygın olduğu diğer alanlarda da uygulamaları bulunmaktadır.

3.2. ESA OLUŞTURULMASI

Konvolüsyonel bir sinir ağı Şekil 3.3' te görüldüğü gibi, bir giriş katmanı, gizli katmanlar ve bir çıkış katmanından oluşur. İleri beslemeli herhangi bir sinir ağı yapısında, orta katmanlar, girişleri ve çıktıları aktivasyon fonksiyonu ve son konvolüsyon tarafından gizlenir, bu yüzden gizli olarak adlandırılırlar. Konvolüsyonel bir sinir ağında, gizli katmanlar konvolüsyon işlemleri gerçekleştiren katmanları içerir. Genellikle, bu, katmanın giriş matrisiyle konvolüsyon çekirdeğinin nokta çarpımını gerçekleştiren bir katmanı içerir. Bu ürün genellikle Frobenius iç çarpımıdır ve aktivasyon fonksiyonu genellikle ReLU'dur. Konvolüsyon çekirdeği katman boyunca giriş matrisi üzerinde kaydırsa, konvolüsyon işlemi bir özellik haritası üretir ve bu bir sonraki katmanın girdisine katkıda bulunur. Bu, havuzlama katmanları, tam bağlantılı katmanlar ve normalizasyon katmanları gibi diğer katmanlar tarafından takip edilir.



Şekil 3.3. Basit ESA katmanlarının genel bakışı [47].

3.2.1. Evrişimli Katman

Konvolüsyonel katman, bir ESA'nın temel bir bileşenidir ve parametreleri olarak küçük bir kabul eden, ancak giriş hacminin tam derinliğini kullanan eğitilebilir filtre veya çekirdek setini kullanır. İleri geçiş sırasında, her filtre genişlik ve yükseklik boyunca konvolüsyon yaparak giriş hacmine uygulanır ve 2 boyutlu bir aktivasyon haritası elde edilir. Bu süreç, ağına belirli özellikleri belirli pozisyonlarda algıladığında etkinleşen filtreleri öğrenmesini sağlar. Konvolüsyonel katmanın tam çıktı hacmi, tüm filtreler için aktivasyon haritalarını derinlik boyutu boyunca yığılarak oluşturulur. Çıktı hacmindeki her bir giriş, küçük bir bölümü inceleyen ve aynı aktivasyon haritasındaki diğer sinir hücreleriyle parametreleri paylaşan bir sinir hücresinin çıktısını temsil eder. Konvolüsyonel katman, giriş verilerinden kenarlar, köşeler ve dokular gibi yerel özellikler çıkarmak için giriş verilerine bir dizi filtre veya çekirdek uygulayarak çalışır. Konvolüsyonel katman tarafından üretilen özellik haritası, giriş verilerinin en uygun ve önemli özelliklerini içerir. Konvolüsyonel katman, konvolüsyon adı verilen bir matematiksel işlemi gerçekleştirir, bu işlemde giriş verisinin küçük bir bölgesinde (alıcı alan olarak adlandırılır) bulunan değerler, filtrenin ilgili değerleriyle çarpılır ve özellik haritası için tek bir çıktı değeri üretmek üzere toplanır. Bu işlem, her bir giriş verisi elemanı için tekrarlanır ve her eleman için farklı bir filtre kullanılarak tam bir özellik haritası oluşturulur [26].

Konvolüsyonel bir katmandaki filtreler genellikle eğitim sürecinde verilerden öğrenilir ve belirli bir görev için en uygun ve yararlı özellikleri çıkarmak için optimize edilir (örneğin, görüntü sınıflandırma, nesne tespiti vb.). Filtreler genellikle

küçüktür, genellikle 3x3 veya 5x5 boyutundadır ve tüm giriş verilerine uygulanır. “Adım” olarak adlandırılan bir adımla belirtilen bir adımla filtrelerin her bir uygulama arasında ne kadar hareket ettiğini belirler. Konvolüsyonel katman, bir ESA’nın önemli bir bileşenidir ve giriş verilerinin yerel özelliklerini çıkarmak ve temsil etmekle sorumludur. Bu, ESA’nın verilerdeki mekansal ve görsel bilgileri yakalamasına ve işlemesine, giriş verilerindeki küçük değişikliklere karşı daha sağlam ve değişmez olmasına olanak tanır. Konvolüsyonel katmanın çıktısı genellikle ağdaki sonraki katmanlara daha fazla işleme ve analiz için iletilir.

3.2.2. Havuzlama Katmanı

ESA, önceki katmanın (genellikle bir konvolüsyonel katman) çıktısının boyutunu ve karmaşıklığını azaltmak için bir havuzlama katmanı kullanılır. Bunun için genellikle ortalama veya maksimum havuzlama gibi bir havuzlama işlemi uygulanır. Bu işlemde, genellikle 2x2 veya 3x3 boyutunda bir giriş veri bölgesi içindeki değerler tek bir değere birleştirilir. Havuzlama katmanının temel amacı, ağdaki parametre sayısını azaltırken konvolüsyonel katmanın özelliklerinin giriş verilerindeki küçük değişikliklere karşı direncini artırmaktır. Konvolüsyonel katman yüksek sayıda özellik haritası üretebilir, bu da hesaplama açısından maliyetli olabilir ve aşırı uydurmalarla yol açabilir, bu nedenle havuzlama katmanı önemlidir. Havuzlama işlemi, giriş verisinin üzerine bindirilmeyen bölgelerine uygulanır ve adım boyutu, havuzlama penceresinin boyutuna eşit olarak kullanılarak giriş verisinin boyutunu 2 veya 4 kat küçültür. Havuzlama katmanı, konvolüsyonel katmanla birlikte çalışarak giriş verilerinin yerel özelliklerini çıkarmak ve temsil etmek için kullanılır ve çıktı genellikle ağdaki sonraki katmanlara daha fazla analiz ve işleme için iletilir.

3.2.3. Maksimum Havuzlama

Maksimum havuzlama, bir evrişimli sinir ağı (ESA) içindeki giriş veri bölgelerinden her birinin maksimum değerini çıktı olarak veren bir havuzlama işlemidir. Bu, giriş verisinin boyutunu küçültmek ve en önemli özelliklerini çıkararak bir olumsuz

örnekleme yöntemidir. Genellikle maksimum havuzlama, yerel özellikleri temsil eden çok boyutlu bir değer dizisi olan bir evrişim katmanının çıktısına uygulanır (aynı zamanda özellik haritası olarak da bilinir). Havuzlama işlemi, özellik haritasını örtüşmeyen bölgelerin bir ızgaraya bölen (genellikle 2x2 veya 3x3) ve ardından her bir bölgeden maksimum değeri çıktı değeri olarak seçme işlemidir. Bu işlem, özellik haritasındaki her bir bölge için tekrarlanır ve havuzlama katmanının çıktısı olarak yeni bir küçültülmüş özellik haritası üretilir.

Maksimum havuzlamanın, ortalama havuzlama veya toplam havuzlama gibi diğer havuzlama yöntemlerine göre birkaç avantajı vardır. Giriş verideki gürültü ve değişikliklere karşı daha sağlamdır, çünkü genellikle her bölgeden en önemli ve belirgin özelliği seçer [27]. Ayrıca hesaplama açısından verimlidir, çünkü veri üzerinde yalnızca bir geçiş gerektirir ve ek parametreler veya hesaplamalar gerektirmez [28].

3.2.4. ReLU Katmanı


Rectified Linear Unit (ReLU) katmanı, ESA içinde giriş veriye ReLU aktivasyon fonksiyonunu uygulayan bir katman türüdür. ReLU aktivasyon fonksiyonu, basit bir doğrusal olmayan fonksiyondur. Eğer giriş değeri pozitifse, giriş değerini çıktı olarak verir; eğer negatifse, 0 olarak çıktı verir. ReLU katmanı genellikle bir ESA'deki evrişim ve havuzlama katmanlarından sonra kullanılır ve giriş veriye eleman bazında uygulanır. Bu, ReLU aktivasyon fonksiyonunun giriş verinin her bir elemanına ayrı ayrı uygulandığı anlamına gelir ve ReLU katmanının çıktısı, her bir elemana ReLU fonksiyonunun uygulandığı giriş verisiyle aynı boyutta yeni bir dizi olur. ReLU katmanının amacı, ağa doğrusal olmayanlık eklemektir, çünkü ağın verideki karmaşık ilişkileri öğrenip modellemesi için doğrusal olmayanlık gereklidir. ReLU aktivasyon fonksiyonu, doğrusal olmayanlığı basit ve verimli bir şekilde tanıtmak için hesaplama açısından verimli, türevlenebilir ve az sayıda parametreye sahip olduğundan kullanılır. ReLU, doğrusal olmayan aktivasyon fonksiyonunu uygulayan ve doymayan bir aktivasyon fonksiyonunun kısaltmasıdır: ReLU, genelizasyon doğruluğuna önemli bir ceza olmaksızın sinir ağını daha hızlı bir şekilde eğittiği için diğer fonksiyonlara göre sıklıkla tercih edilir.

3.2.5. Kayıp Katmanı

Bir kayıp katmanı, bir ESA bir katman türüdür. Bu katman, ağın tahmin edilen çıktısı ile gerçek çıktı arasındaki hata veya kaybı hesaplar. Kayıp katmanı genellikle ağın son katmanıdır ve ağın performansını ölçmek ve eğitim sürecini yönlendirmek için kullanılır [29]. Kayıp katmanının çıktısı, ağın ne kadar iyi performans gösterdiğini gösteren bir skaler değer olan kayıp değeridir. Kayıp değeri, tahmin edilen ve gerçek çıktıların kayıp fonksiyonunun uygulanmasıyla hesaplanır ve genellikle ağ parametreleriyle ilgili kaybın gradyanını hesaplamak için kullanılır. Bu gradyan daha sonra kaybı azaltan ve ağın performansını artıran yönde ağ parametrelerini güncellemek için kullanılır. Kayıp katmanı veya kayıp fonksiyonu, ağın tahmin edilen çıktısı ile gerçek veri etiketleri arasındaki sapmayı nasıl cezalandırdığını belirtir.

3.2.6. Softmax Fonksiyonu

Şekil 4’ te görüldüğü gibi Softmax, genellikle bir ESA son katman olarak kullanılan ve çıktı sınıfları üzerinde olasılık dağılımı oluşturmak için sıklıkla kullanılan bir fonksiyondur. Gerçek değerlerden oluşan bir vektörü giriş olarak alır ve her sınıfın tahmin edilen olasılığını gösteren, 0 ile 1 arasında değerler üreten ve toplamı 1 olan bir vektörü üretir. Standart softmax fonksiyonu genellikle sinir ağı tabanlı bir sınıflandırıcıdaki son katmanda kullanılır. Bu tür ağlar genellikle logaritmik kayıp (veya çapraz entropi) yaklaşımı kullanılarak eğitilir ve çoklu nominal lojistik regresyonun doğrusal olmayan bir varyasyonunu sonuçlar [30]. Özetlemek gerekirse, softmax fonksiyonu, gerçek değerlerden oluşan bir vektörü giriş olarak alır ve her sınıfın tahmin edilen olasılığını temsil eden 1’e toplanan olasılık vektörünü çıktı olarak verir. Sonuç olarak, softmax fonksiyonu, bir ESA’da kullanmak için birkaç faydalı özelliğe sahiptir [31].



Şekil 3.4. ESA’da pooling katmanı ve softmax [48].

3.3. DEĞERLENDİRME METRİKLERİ

Kesinlik değerlerini bir araya getirerek, bir modelin pozitif ve negatif örnekleri doğru şekilde sınıflandırma yeteneğini dengeleyen tek bir değer sunar.

Kesinlik ve Geri Çağırma’nın Anlaşılması: Kesinlik: Kesinlik, pozitif olarak tahmin edilen doğru örneklerin (gerçek pozitifler) tüm pozitif olarak tahmin edilen örneklerin oranına karşılık gelir. Bir modelin yanlış pozitif tahminlerden kaçındığı şekilde ne kadar iyi performans gösterdiğini ölçer ve gerçek pozitiflerin, gerçek pozitiflerin ve yanlış pozitiflerin toplamına bölünerek hesaplanır.

Geri Çağırma: Geri çağırma, aynı zamanda duyarlılık veya gerçek pozitif oranı olarak da bilinir ve bir modelin pozitif örnekleri doğru bir şekilde tespit etme yeteneğini ölçer. Gerçek pozitiflerin, tüm gerçek pozitif örneklerin oranını hesaplar. Geri çağırma, gerçek pozitiflerin, gerçek pozitiflerin ve yanlış negatiflerin toplamına bölünerek hesaplanır.

F1 Puanı:


F1 puanı, kesinlik ve geri çağırmanın harmonik ortalamasıdır. Bu iki metriği dengeleyerek, ikili sınıflandırma görevlerinde bir modelin genel performansını temsil eden tek bir değer sağlar. F1 puanı, 0 ile 1 arasında değer alır, 1 mükemmel bir modeli, 0 ise zayıf performansı gösterir.

Matematiksel olarak, F1 puanı aşağıdaki formül kullanılarak hesaplanır:

$$F1 \text{ puanı} = 2 * (\text{kesinlik} * \text{geri çağırma}) / (\text{kesinlik} + \text{geri çağırma})$$
 Formüldeki harmonik ortalama, F1 puanının kesinlik ve geri çağırma arasındaki daha düşük değerden etkilenmesini sağlar, bu da dengesiz sınıf dağılımlarına duyarlılık kazandırır.

3.4. K- KATLAMALI ÇAPRAZ DOĞRULAMA

Şekil 3.5’ te K-Katlamalı doğrulama tekniği, veriyi k-alt kümelerine bölmeyi ve ardından k kez ayırım yöntemini tekrarlamayı içerir. Her bir k alt küme test seti olarak kullanılırken, geriye kalan k-1 alt küme eğitim amacıyla kullanılır [34]. Başlangıçta veriyi eğitim ve test setlerine bölebiliriz, ancak bu yöntem şans faktöründen dolayı modelin performansını doğru bir şekilde yansıtmayabilir. Bu sorunu çözmek için, çapraz doğrulama yöntemini kullanabiliriz. Bu yöntem, mevcut girdi verisinin alt kümeleri üzerinde birkaç makine öğrenmesi modelini eğitip, modelin performansını değerlendirmek için verinin tamamlayıcı alt kümesini kullanmayı içerir. Çapraz doğrulama, modelin genel olarak performansını değerlendirmek için kullanılabilir. Ayrıca, çapraz doğrulama, modelin aşırı uyum (overfitting) [35]. durumunu tespit etmek için de kullanılabilir. Aşırı uyum, modelin bir deseni genelleme becerisini kaybettiği durumdur.



Şekil 3.5. K katlamalı çapraz doğrulama (K-fold Cross Validation) [36].

K-katlamalı çapraz doğrulama, bir makine öğrenme modelinin performansını değerlendirmek için kullanılan bir tekniktir. Bu yöntem, veri setini rastgele olarak k alt kümeye veya "katlamaya" bölmeyi içerir [31]. Model daha sonra k-1 katlama üzerinde eğitilirken, geriye kalan katlama test seti olarak kullanılır. Bu süreç k kez tekrarlanır ve her bir katlama bir kez test seti olarak kullanılır. Tüm k tekrarlamaların ortalaması, modelin performansını değerlendirmek için kullanılır [36]. K-katlamalı çapraz doğrulama, tek bir eğitim-test bölmesine göre modelin performansının daha doğru bir tahminini sağlar. Bu, her tekrarlamada modelin farklı veri alt kümeleri üzerinde test edilmesiyle, performansının daha kapsamlı bir şekilde anlaşılmasını sağlar. Bir araştırma makalesinde, k-katlamalı çapraz doğrulama, modelin performansını çeşitli veri setlerinde değerlendirmek ve güvenilirliğini, sağlamlığını göstermek için kullanılabilir [37].

BÖLÜM 4

TASARLANAN MODELİN ÖZELLİKLERİ

Bu çalışmada, AH sınıflandırması, manyetik rezonans görüntüleme ile elde edilen üç boyutlu beyin görüntüleri kullanılarak yapılmıştır. Hastalık dört farklı sınıfa (“hafif, orta, orta ileri, şiddetli”) ayrılmıştır. Bu çalışmada, Python programlama dili ve Google Colab not defteri kullanılmıştır. Kullanıcılara Python kodu yazma, çalıştırma ve işbirliği yapma imkanı sağlayan bir web tabanlı platform olan Google Colab bir çalışma ortamı sunmaktadır. Genel olarak, önerilen ESA modeli, düşünceli bir mimari tasarım, etkili özellik çıkarma yetenekleri ve aşırı uydurmaya karşı düzenleme teknikleri göstermektedir. Ayrıca, standart ESA uygulamalarıyla uyumluluğu sayesinde görüntü sınıflandırma görevleri için umut verici bir yaklaşım olarak öne çıkmaktadır.


4.1. VERİ SETİ

Sağlanan veri seti, Eğitim ve Test olmak üzere iki dosyadan oluşur ve her biri yaklaşık olarak 6400 görüntü içerir. Bu görüntüler, AH’nın şiddetine göre kategorize edilmiş olup dört farklı sınıfa ayrılmıştır. Çizelge 4.1’de veri seti görüntü miktarı ve ilgili sınıflandırmaları sunulmuştur


Çizelge 4.1. Veri Seti Görüntü Miktar.

Görüntü Türü	Veri sayısı	Sınıf
Hafif Demanslı	717	0
Orta Demans	52	1
Demanssız	2560	2
Çok Hafif Demanslı	1792	3

Görüntüler üzerinde ön işleme yapılmış olup, veri seti genelinde tutarlı bir boyuta yeniden boyutlandırma işlemi gerçekleştirilmiştir. Ayrıca, veri seti, makine öğrenmesi amaçları için her bir sınıfa ikili bir temsil atayan one-hot etiketleme işleminden geçmiştir. Sağlanan özet, Eğitim ve Test veri setlerindeki dört sınıf arasındaki görüntü dağılımını ve her bir sınıfın kısa bir açıklamasını belirtmektedir. Bu bilgi, veri seti kullanılarak AH sınıflandırmasıyla ilgili daha fazla analiz ve modelleme görevleri için değerli olacaktır. Şekil 4.1 ve 4.2 demansın çeşitli aşamalarını temsil eden görüntülerin dağılımı detaylı olarak sunulmaktadır.

Demans Durumu	Görüntü	Veri Sayısı
Çok Hafif Demanslı		1792
Hafif Demanslı		717
Orta Derecede Demanslı		52
Demans Olmayan		2560

Şekil 4.1. Tedavi öncesi beyin resimleri.



Şekil 4.2. Eğitim veri seti görüntü örnekleri.

4.2. YÖNTEM ÖZETİ


İlk olarak, dört farklı sınıfa (“Çok Hafif Demanslı, Hafif Demanslı, Orta Derecede Demanslı, Demans Olmayan”) sahip 6400 MRG beyin 3D görüntüsü içeren bir veri seti kullandık. Ardından, TensorFlow’u kullanarak verileri basit ve hızlı bir yöntemle okuduk. Ayrıca, TensorFlow 2.3’ün kolay veri yükleme araçları gibi yeni özelliklere sahip olduğunu belirtmek gerekir. Daha sonra, görüntüleri önışledik ve her bir görüntüdeki özellikleri One-hot kodlaması kullanarak çıkardık ve eğitim ve doğrulama veri setlerimizi önceliklendirerek hedef veri setimizi tanımladık.

Veri setlerimizin dengesiz olması nedeniyle model değerlendirmesi için doğruluk eğrisini kullandık. Ardından, Keras’ı kullanarak sıfırdan özelleştirilmiş ESA modelimizi oluşturduk ve modelimizi eğitmek ve ayrı test görüntülerinde test etmek

için "adam" optimize ediciyi kullanarak derledik. eğitim ve doğrulama işlemlerinden sonra en iyi doğruluğu, 60 Epoch üzerinde eğittiğimiz sıralı özel ESA modelimizde elde ettik. Eğitim verisi için %97 doğruluk elde ettik ve test verisi için %85 doğruluk elde ettik.

4.3. VERİ YÜKLEME


Eğitim ve doğrulama veri setleri için %80 %20 bölme yöntemini kullanılmıştır. Eğitim veri setini genişletmek için veri artırma yöntemleri uygulandı ve bu işlemler TensorFlow ile gerçekleştirildi. Şekil 4.3'te, model tarafından işlenen görüntü verilerinden bazı örnekler gösterilmektedir.



Şekil 4.3. Eğitim veri seti görüntü örnekleri.

- ModelCheckpoint, eğitim sürecinde iyi bir sonuç elde etmek için uzun süre gerektiren durumlarda sıklıkla çok sayıda iterasyon gereklidir. Bu durumda, metrikleri iyileştiren bir epoch sona erdiğinde yalnızca en iyi performans gösteren modelin bir kopyasını kaydetmek daha iyidir. ModelCheckpoint, makine öğrenmesi modelinde bir tür geri çağırma (callback) olan ve eğitim sürecinin her bir epoch (iterasyon) sonrasında modelin bir kopyasını kaydeden bir mekanizmadır, ancak yalnızca modelin performansı doğrulama setinde iyileşirse kaydetme işlemi gerçekleştirilir.

- Şekil 4.4’ te görülen Erken durdurma, bazen eğitim sırasında, genellemenin boşluğu (yani eğitim ve doğrulama hatası arasındaki fark) azalmak yerine artmaya başladığını fark edebiliriz. Bu, aşırı uydurmanın bir belirtisidir ve model kapasitesini azaltma, eğitim verisini artırma, veri artırma, düzenleme (regularization), dropout gibi birçok yöntemle çözülebilir. Genellikle pratik ve etkili bir çözüm, genellemenin boşluğu kötüleştiğinde eğitimi durdurmaktır.



Şekil 4.4. Erken durdurma [49].

4.4. KULLANILAN TEKNOLOJILER

Derin öğrenme konusunda, çevre ve araçların seçimi genellikle sinir ağlarının etkili bir şekilde uygulanmasını sağlayan çerçeveler etrafında dönüyor ve GPU hızlandırmasını destekliyor. Kullanılan bazı araçlar ve ortamlar:

4.4.1. Tensorflow

TensorFlow kütüphanesi, makine öğrenimi uygulamaları geliştirmek için açık kaynak bir platformdur. Derin sinir ağlarını eğitme, veri akışlarını kullanarak mantıksal çıkarımlar yapma ve farklılanabilir programlama gibi çeşitli görevleri yerine getirmek için sembolik bir bilimsel disiplin kütüphanesidir. Makine öğrenimi modellerini oluşturmak, eğitmek, verileri işlemek ve analiz etmek için kullanılan bir platformdur. Ancak, TensorFlow’den önce veri ön işleme aşamasında diğer araçlar ve kütüphaneler kullanılabilir. Örneğin, NumPy veya Pandas gibi kütüphaneler, farklı kaynaklardan veri okuma, yükleme, veriyi bölebilme ve TensorFlow’da

kullanılan matematiksel ifadeler olan tensörlere dönüştürme gibi işlemler için kullanılabilir. Diğer kütüphaneler kullanılarak veriler hazırlandıktan sonra, TensorFlow işlenmiş veriler üzerinde makine öğrenimi modelleri oluşturmak ve eğitmek için kullanılabilir. TensorFlow, matematiksel işlemler yapma, modelleri yönetme ve performansı optimize etme gibi makine öğrenimi işlemlerini gerçekleştirmede kolaylık sağlayan geniş bir işlev ve araç yelpazesine sahiptir. TensorFlow, bu işlemleri etkili ve verimli bir şekilde gerçekleştirmeye yardımcı olan güçlü bir çerçevedir [32].

4.4.2. Keras

Keras, TensorFlow kütüphanesi için bir arayüz görevi görür. Keras, TensorFlow dahil olmak üzere birden fazla arka uç üzerinde desteklenmektedir. Keras, derin öğrenme modelleri oluşturmak ve eğitmek için kullanılan açık kaynaklı bir yazılım kütüphanesidir. Python'da yazılmış olup kullanıcı dostu, modüler ve genişletilebilir olacak şekilde tasarlanmıştır. Keras, TensorFlow ve Theano gibi diğer popüler derin öğrenme kütüphanelerinin üzerine inşa edilmiştir ve sinir ağı modellerini tanımlamak ve eğitmek için yüksek seviye bir arayüz sağlar. Keras, araştırmacıların ve geliştiricilerin derin öğrenme ile deney yapmasını, hızlı prototip oluşturmalarını ve yeni modeller geliştirmelerini kolaylaştırmak için geliştirilmiştir. Ayrıca veri ön işleme, eğitim ve değerlendirme için çeşitli araçlar ve yardımcı programlar sunar ve hem araştırma hem de üretim ortamları için kullanılabilir [33].

4.4.3. Numpy Kütüphanesi

NumPy, Numerical Python kısaltmasıdır ve özellikle sayısal veriler için Python'da bilimsel programlama için kullanılan bir kütüphanedir. NumPy, üçüncü boyutta nesneleri içeren diziler ve Python uygulamaları için bir dizi işlem aracı paketi içerir. Temel olarak, C ve Python'un bir kombinasyonudur ve geçmişte kullanılan MATLAB programlamasına bir alternatif olarak kullanılır. Sayılar şeklindeki veriler üçüncü boyutlu işlevler ve dönüşüm işlemleri için diziler olarak işlenir. NumPy dizileri, normal Python listelerine benzer, ancak sayısal işlemler için daha verimli ve optimize edilmiştir. NumPy ayrıca matrisler ve dizilerle çalışmak için geniş bir işlev

ve yöntem yelpazesi sağlar. Bunlar arasında matematiksel işlemler, lineer cebir ve istatistiksel analiz için fonksiyonlar bulunur.

4.4.4. Pandas Veri İşleme Kütüphanesi

Pandas, etiketli veya ilişkisel verilerle çalışmak için öncelikle oluşturulan açık kaynaklı bir kütüphanedir ve basit ve sezgisel bir şekilde veri manipülasyonu yapmayı sağlar. Sayısal verileri ve istatistikleri işlemek için çeşitli veri yapıları ve işlemler sağlar. Bu kütüphane, NumPy kütüphanesi üzerine inşa edilmiş olup hızlı bir şekilde çalışır ve kullanıcılar için yüksek performans ve üretkenlik sunar. Pandas, Python'da veri manipülasyonu ve analizi için popüler bir yapılandırılmış ve yapılandırılmamış veri kümeleriyle çalışmak için yüksek performanslı, kullanımı kolay veri yapıları ve veri analizi araçları sağlar. Pandas'taki temel veri yapısı DataFrame'dir ve satır ve sütunlardan oluşan iki boyutlu bir tablo veri yapısıdır. DataFrame'ler, ilişkisel bir veritabanındaki tablolara benzer ve çeşitli yerleşik yöntemler ve işlevler kullanılarak kolayca manipüle edilebilir, dönüştürülebilir ve analiz edilebilir.

BÖLÜM 5


SONUÇLAR

Çizelge 5.1’ de modelin mimari detayları verilmektedir.

Çizelge 5.1. Önerilen ESA modelin mimari detayları.


Layer (type)	Output Shape	Param
conv2d (Conv2D)	(None, 224, 224, 16)	448
conv2d_1 (Conv2D)	(None, 224, 224, 16)	2320
max_pooling2d (MaxPooling2D)	(None, 112, 112, 16)	0
sequential (Sequential)	(None, 56, 56, 32)	2160
sequential_1 (Sequential)	sequential_1 (Sequential)	7392
sequential_2 (Sequential)	(None, 14, 14, 128)	27072
dropout (Dropout)	dropout (Dropout)	0
sequential_3 (Sequential)	(None, 7, 7, 256)	103296
dropout_1 (Dropout)	(None, 7, 7, 256)	0
flatten (Flatten)	(None, 12544)	0
sequential_4 (Sequential)	(None, 512)	6425088
sequential_5 (Sequential)	(None, 128)	66176
sequential_6 (Sequential)	(None, 64)	8512
dense_3 (Dense)	(None, 4)	260
Total params 6,642,724		
Trainable params: 6,640,356		
Non-trainable params: 2,368		

60 epoch üzerinde eğitilen model ile %97 eğitim doğruluğu, değerlendirme sonrası modelin testi için %85 başarı elde edilmiştir. Aşağıda Şekil 5.1’de gösterildiği gibi doğruluk eğrileri şöyledir:



Şekil 5.1. Çapraz doğrulama sonrası model doğruluğu ve kayıp grafiği.

Tahminlerin ayrıntılı bir şekilde analiz edilmesi Şekil 5.2’te aşağıda gösterildiği gibi control edilmiştir.



Şekil 5.2. Çapraz doğrulama sonrası karmaşıklık matrisi.

Son olarak, modelimi iyileştirmek için k katlamalı çapraz doğrulama kullanılmıştır. Beş parçalı katlamada %88 doğruluk elde edildi. Genel olarak, karmaşıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek ve analiz etmek için değerli bir araçtır. Son olarak, çapraz doğrulama sonrası F1 skor metriğini olarak %89 elde edilmiştir. Önerdiğimiz model ile Bölüm 2’de bahsedilen diğer makaleler

arasında bir karşılaştırma yapabiliriz. Aşağıda Çizelge 5.2.'te tablosunu görülmektedir.

Çizelge 5.2. Önerdiğimiz modelin diğer modellerle karşılaştırılması.

Makale	Doğruluk	Veri Seti	Model
[9]	75%	ADNI'den 3B T1-ağırlıklı görüntüler (3D T1-weighted)	CNN özel modeli
[8]	92%	OASIS veri setinde 416 katılımcı sahiptir	DenseNet-121
[7]	73%	OASIS veri seti	CNN -RMSPProp algoritması
Bu araştırmanın modeli	97%	Alzheimer Hastalığı Beyin Veri Seti	CNN – Özel geliştirilmiş model

5.1. TARTIŞMA

Bu çalışmada, AH'nın sınıflandırılmasında 2B ESA'lar kullanımı incelenmiştir. AH olan hastalar ve sağlıklı kontrol grubundan alınan MRG taramaları veri seti üzerinde bir 2B ESA eğittik ve modelin AH olan hastaları %90'a yakın doğrulukla sınıflandırabildiğini tespit edilmiştir.

Bu sonuç, 2B ESA'ların AH teşhisinde doğruluğu ve verimliliği artırma potansiyeline sahip olduğunu göstermektedir. Bu modeller, tıbbi görüntülerden otomatik olarak özellikler öğrenebilir ve hastaları görüntüleme verilerine dayanarak sınıflandırabilir, bu da subjektif değerlendirmelere dayanan geleneksel yöntemlere göre daha doğru ve güvenilir olabilir.

Ancak, çalışmamızın kapsamı sınırlı olduğunu ve AH'nın sınıflandırılması için 2B ESA'ların yeteneklerini ve sınırlamalarını tam anlamıyla anlamak için daha fazla araştırmaya ihtiyaç duyulduğunu belirtmek önemlidir. Bunlar, bu modellerin daha büyük ve daha çeşitli veri kümelerinde performanslarının değerlendirilmesini ve klinik uygulamada kullanma potansiyellerinin araştırılmasını içerir.

BÖLÜM 6

SONUÇ VE GELECEK ÇALIŞMALAR

Sonuç olarak, bu araştırma, AH'nın sınıflandırılmasında 2B ESA'lar için potansiyeli göstermiştir. Beyin MRG taramalarının bir veri seti kullanılarak bir 2B ESA eğitildi ve AH olan hastaları %90'a yakın doğrulukla sınıflandırabildiğimizi görülmüştür. Bu sonuç, 2B ESA'ların AH'nın teşhisinde doğruluğu ve verimliliği artırmak için umut verici bir araç olabileceğini düşündürmektedir.

Gelecek çalışmalar açısından, çalışmamızın kapsamını daha çeşitli hasta popülasyonlarını kapsayacak şekilde genişletmeyi ve 2B ESA'ların farklı tipte tıbbi görüntü verileri üzerindeki performansını değerlendirmeyi planlıyoruz. Ayrıca, bu modellerin hastalık ilerlemesinin ve tedaviye yanıtın tahmin edilmesi gibi diğer uygulamalarda kullanma potansiyellerinin araştırılması planlanmaktadır.

Genel olarak, AH'nın sınıflandırılmasında 2B ESA'ların kullanımı, bu zorlu hastalığın teşhis ve yönetiminde büyük umut vaat etmektedir. Bu modellerin potansiyelini tam olarak anlamak ve klinik uygulamadaki yerlerini belirlemek için daha fazla araştırmaya ihtiyaç vardır.

KAYNAKLAR

- [1] Scheltens, P., De Strooper, B., Kivipelto, M., Holstege, H., Ch  telat, G., Teunissen, C. E., & van der Flier, W. M. "Alzheimer's disease".The **Lancet**, 397(10284), 1577-1590. 2021.
- [2] Ballard, C., Gauthier, S., Corbett, A., Brayne, C., Aarsland, D., & Jones, E. . "Alzheimer's disease".the **Lancet**,377(9770), 1019-1031. 2011.
- [3] Joe, E., & Ringman, J. M. "Cognitive symptoms of Alzheimer's disease: clinical management and prevention".**bmj**,367. 2019.
- [4] Rahul S. Desikan and others, "Automated MRI measures identify individuals with mild cognitive impairment and Alzheimer's disease",**Brain**, Volume 132, , Pages 2048–2057, Issue 8, August 2009. <https://doi.org/10.1093/brain/awp123>
- [5] Suganthe, R. C., Geetha, M., Sreekanth, G. R., Gowtham, K., Deepakkumar, S., & Elango, R. "Multiclass classification of Alzheimer's disease using hybrid deep convolutional neural network".NVEO-NATURAL VOLATILES & ESSENTIAL OILS Journal| **NVEO**, 145-153. 2021.
- [6] Chong, P., Tan, Y. X. M., Guarnizo, J., Elovici, Y., & Binder, A. "Mouse authentication without the temporal aspect–what does a 2d-cnn learn?". In IEEE Security and Privacy Workshops (SPW) (pp. 15-21). **IEEE**. 2018
- [7] Hong, S. Y., Yao, L. H., Cheah, W. T., Chang, W. D., Fu, L. C., & Chang, Y. L.. "A novel screening system for alzheimer's disease based on speech transcripts using neural network". In 2019 IEEE International Conference on Systems, Man and Cybernetics (**SMC**) (pp. 2440-2445). **IEEE**. 2019.
- [8] Akbari, A., Ng, L., & Solnik, B. "Drivers of economic and financial integration: A machine learning approach". **Journal of Empirical Finance**, 61, 82-102. 2021
- [9] Eker, A. and Duru, N., "Medikal G  r  nt   İ  lemede Derin   ğrenme Uygulamaları", **Acta Infologica**, (2021).
- [10] T. Altaf, S. M. Anwar, N. Gul, M. N. Majeed, and M. Majid, "Multi-class Alzheimer's disease classification using image and clinical features," **Biomedical Signal Processing and Control**, vol. 43, pp. 64-74, 2018.

- [11] Han, X. “MR-based synthetic CT generation using a deep convolutional neural network method”. *Medical physics*, 44(4), 1408-1419. 2017
- [12] McKhann, Guy M., et al. “The diagnosis of dementia due to Alzheimer’s disease: Recommendations from the National Institute on Aging-Alzheimer’s Association workgroups on diagnostic guidelines for Alzheimer’s disease.” *Alzheimer’s & dementia* 7.3: 263-269. 2011
- [13] “Recommendations from the National Institute on Aging-Alzheimer’s Association workgroups on diagnostic guidelines for Alzheimer’s disease,” *Alzheimer’s & dementia*, vol. 7, no. 3, pp. 263-269, 2011.
- [14] M. Prince, R. Bryce, E. Albanese, A. Wimo, W. Ribeiro, and C. P. Ferri, “The global prevalence of dementia: a systematic review and metaanalysis,” *Alzheimer’s & dementia*, vol. 9, no. 1, pp. 63- 75. e2, 2013.
- [15] S. G. Mueller et al., “The Alzheimer’s disease neuroimaging initiative,” *Neuroimaging Clinics*, vol. 15, no. 4, pp. 869-877, 2005.
- [16] E. Arvesen, “Automatic classification of alzheimer’s disease from structural MRI,” 2015.
- [17] J. Islam and Y. Zhang, “A novel deep learning based multi-class classification method for Alzheimer’s disease detection using brain MRI data,” in International Conference on Brain Informatics, , pp. 213-222: *Springer*. 2017.
- [18] J. Islam and Y. Zhang, “An Ensemble of Deep Convolutional Neural Networks for Alzheimer’s Disease Detection and Classification,” *arXiv* preprint arXiv:1712.01675, 2017.
- [19] S. Basaia et al., “Automated classification of Alzheimer’s disease and mild cognitive impairment using a single MRI and deep neural networks,” *NeuroImage: Clinical*, p. 101645, 2018.
- [20] S. Spasov, L. Passamonti, A. Duggento, P. Liò, N. Toschi, and A. s. D. N. Initiative, “A parameter-efficient deep learning approach to predict conversion from mild cognitive impairment to Alzheimer’s disease,” *Neuroimage*, vol. 189, pp. 276-287, 2019.
- [21] Degrange t, flamm c, feistel r, and bornholdt “efficient numerical computation of evolutionary dynamics”, 2018.
- [22] Géron, Aurélien, “Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow”. Sebastopol, CA: O’Reilly Media. ISBN 978-1-492-03264-9., pp. 448, 2019.
- [23] Zhang, Y., Dong, Z., Phillips, P., Wang, S., Ji, G., Yang, J., & Yuan, T. F. . “Detection of subjects and brain regions related to Alzheimer’s disease using

- 3D MRI scans based on eigenbrain and machine learning. *Frontiers in computational neuroscience*, 9, 66, 2015
- [24] Venkatesan, Ragav; Li, Baoxin “Convolutional Neural Networks in Visual Computing: A Concise Guide”. **CRC Press**. ISBN 978-1-351-65032-8, 2017.
 - [25] Pröve, Paul-Louis “An Introduction to different Types of Convolutions in Deep Learning”, 2018.
 - [26] Haq, I Gondal, P Vamplew “Categorical Features Transformation with Compact One-Hot Encoder for Fraud Detection in Distributed Environmen”t: 16th Australasian Conference, **AusDM**, 2018.
 - [27] Khashayar Namdar, Masoom A. Haider and Farzad Khalvati, “A Modified AUC for Training Convolutional Neural Networks: Taking Confidence Into Accoun” t, 2021.
 - [28] Tingting Zhang, Zhenghua Lin, Zhiyuan Liu, and Maosong Sun “Classification of Alzheimer’s disease using machine learning techniques” 2019.
 - [29] Krizhevsky, A.; Sutskever, I.; Hinton, G. E. “Imagenet classification with deep convolutional neural networks” (PDF). *Advances in Neural Information Processing Systems*. 1: 1097–1105, 2012
 - [30] Graham, Benjamin. “Fractional Max-Pooling”. *arXiv*:1412.6071. 2014
 - [31] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun “Deep residual learning for image recognition”. **CVPR**, 2016.
 - [32] Scherer, Dominik; Müller, Andreas C.; Behnke, Sven, “Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition” (PDF). *Artificial Neural Networks (ICANN)*, 20th International Conference on. Thessaloniki, Greece: **Springer**. pp. 92–101. 2010
 - [33] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton “ImageNet classification with deep convolutional neural networks” 2017.
 - [34] Jason Brownlee “Loss and Loss Functions for Training Deep Learning Neural Networks”, **Machine Learning Mastery**, 2019.
 - [35] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich “Going deeper with convolutions” In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1-9. 2015.
 - [36] Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron “6.2.2.3 Softmax Units for Multinoulli Output Distributions”. *Deep Learning*. **MIT Press**. pp. 180–184. ISBN 978-0-26203561-3. 2016
 - [37] HE, Jinbo; FAN, Xitao. Evaluating the performance of the k-fold cross-validation approach for model selection in growth mixture

- modeling. *Structural equation modeling: A multidisciplinary Journal*, 26.1: 66-79, 2019
- [38] Ramasubramanian, Karthik, et al. "Model Performance Improvement." *Machine Learning Using R*: 465-517. (2017)
 - [39] Scott, Philip J., et al. "Informatics for Health 2017: Advancing both science and practice." *Journal of Innovation in Health Informatics* (2017).
 - [40] CML, Myelogenous Leukemia. Young Investigator Awards Program Abstracts. *Am J Clin Pathol*, 142: 700-723 , 2014
 - [41] Michael W. Weiner, John C. Morris, Mark A. Mintun, and Clifford R. Jack "Alzheimer's Disease Neuroimaging Initiative (ADNI): Development and Implementation of Data Sharing".
 - [42] Jahanshad, Neda, et al. "Genome-wide scan of healthy human connectome discovers SPON1 gene variant influencing dementia severity." *Proceedings of the National Academy of Sciences* 110.12 (2013): 4768-4773.
 - [43] CUI, Zhenyu, et al. Alzheimer's disease diagnosis using enhanced inception network based on brain magnetic resonance image. In: *2019 IEEE international conference on bioinformatics and biomedicine (BIBM)*. IEEE, 2019. p. 2324-2330.
 - [44] Jabason, Emimal, M. Omair Ahmad, and M. N. S. Swamy. "Classification of Alzheimer's Disease from MRI Data Using a Lightweight Deep Convolutional Model." *2022 IEEE International Symposium on Circuits and Systems (ISCAS)*. IEEE, 2022.
 - [45] <https://www.alzheimersla.org/wp-content/uploads/2021/04/Understanding-Memory-Loss-Alzheimers-disease-the-basics.jpg-400x400.png>
 - [46] Roy, Shuvendu, and Sneha Paul. "Land-Use Detection Using Residual Convolutional Neural Network." *1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)*, pp. 1-6. *IEEE*, 2019
 - [47]. RAUSCHENBERGER, Maria; BAEZA-YATES, Ricardo. Recommendations to Handle Health-related Small Imbalanced Data in Machine Learning. 2020.
 - [48] LIU, Jiatian. Convolutional neural network-based human movement recognition algorithm in sports analysis. *Frontiers in psychology*, 2021, 12: 663359.
 - [49] Introduction to Deep Learning. [Online]. Available: <https://abhijitramesh.me/blog/part1-following-along-mit-intro-to-deep-learning>, MIT [Accessed 20 8 2023].

- [50] Sandler, Mark, et al. “Mobilenetv2: Inverted residuals and linear bottlenecks.” Proceedings of the *IEEE* conference on computer vision and pattern *recognition*. 2018.
- [51] Alzubaidi, Laith, et al. “Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions.” *Journal of big Data* 8: 1-74. (2021)
- [52] Akay, Metin, et al. “Deep learning classification of systemic sclerosis skin using the MobileNetV2 model.” *IEEE Open Journal of Engineering in Medicine and Biology*: 104-110. 2 (2021)



ÖZGEÇMİŞ

Rabeea salim Fadaam FADAAM ilk ve orta öğrenimini Al Anbar'da tamamladı. 2007 yılında lisans eğitimi için Almaarif University College Üniversitesi bilgisayar Bilimleri Bölümü'nde öğrenimine başlayarak 2010 yılında mezun oldu. Tarım Bakanlığında memur olarak çalıştım. 2020 yılında Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı altında sürdürmektedir.

