

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MANYETİK REZONANS GÖRÜNTÜLERİNDE ALZHEİMER
HASTALIĞININ TESPİTİ İÇİN YENİ DERİN ÖĞRENME MODELLERİNİN
GELİŞTİRİLMESİ

YÜKSEK LİSANS TEZİ

Eyup HANBAY

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Ali ARI

AĞUSTOS 2023

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MANYETİK REZONANS GÖRÜNTÜLERİNDE ALZHEİMER
HASTALIĞININ TESPİTİ İÇİN YENİ DERİN ÖĞRENME MODELLERİNİN
GELİŞTİRİLMESİ

YÜKSEK LİSANS TEZİ

Eyup HANBAY
(36203619002)

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Ali ARI

AĞUSTOS 2023

TEŐEKKÜR VE ÖNSÖZ

Bu tez alıőmasının her aőamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgmeden beni her konuda yönlendiren danışman hocam Sayın Dr. Öğr. Üyesi Ali ARI'ya,

Akademik eğitimim boyunca bana destek olan ve tez çalışmam süresince bilgi ve birikimlerini benden esirgemeyen kıymetli hocam Dr. Öğr. Üyesi Hüseyin ÜZEN' e

Yüksek Lisans eğitimim boyunca çalıştığım kurumda, beni sürekli motive edip desteklerini esirgemeyen kurum müdürüm Abdulkadir ÇOLAK' a, bölge olarak yaşadığımız deprem afetinde zorluk ve imkansızlıklara rağmen yanımda duran kıymetli babam, annem, kardeşlerim, eşim ve çocuklarıma,

teőekkür ederim.

ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduđum “Manyetik Rezonans Görüntülerinde Alzheimer Hastalığının Tespiti için Yeni Derin Öğrenme Modellerinin Geliştirilmesi” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Eyup HANBAY



İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ	i
ONUR SÖZÜ	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	iv
ŞEKİLLER DİZİNİ.....	v
SEMBOLLER VE KISALTMALAR	vi
ÖZET	vii
ABSTRACT	viii
1. GİRİŞ	1
1.1 Alzheimer Hastalığı (AH).....	1
1.1.1 Alzheimer hastalığı ve semptomları	1
1.1.2 Alzheimer hastalığı evreleri	2
1.1.3 Alzheimer hastalığı tanı teknikleri.....	3
1.2 Literatürde Yapılan Çalışmalar	5
1.3 Tezin Amacı.....	8
2. DERİN ÖĞRENME.....	9
2.1 Evrişimsel Sinir Ağlarının (ESA) Bileşenleri:	9
2.1.1 Evrişim katmanı	10
2.1.2 Havuzlama katmanı	11
2.1.3 Yukarı örnekleme katmanı.....	11
2.1.4 Aktivasyon fonksiyonu	12
2.1.5 Tam bağlı katman	12
2.1.6 Giriş ve çıkış katmanı	13
2.1.7 Dropout katmanı	13
2.2 ESA Mimarilerinde Kullanılan Blok Yapıları	13
2.2.1 Kaybolan gradyan problemi.....	14
2.2.2 Eklemeli bağlantı: Artık bağlantı modeli.....	14
2.2.3 Birleştirmeli bağlantı: Dense blok modeli	15
2.2.4 VGGNet mimarisi	16
2.2.5 Inception mimarisi	17
3. MATERYAL VE METOT	19
3.1 Alzheimer Veri Kümesi	19
3.2 Geliştirilen Özel Blok Yapılı Derin Öğrenme Modelleri.....	21
3.2.1 Model 1: Inception-ResNet.....	22
3.2.2 Model 2: Geleneksel evrişim -Inception.....	23
3.2.3 Model 3: ResNet-Geleneksel evrişim	23
3.2.4 Model 4: Inception-Inception	23
3.2.5 Model 5: ResNet-Inception.....	24
4. UYGULAMA VE DEĞERLENDİRME	25
4.1 Değerlendirme Metrikleri.....	25
4.2 Geliştirilen Modellerin Sınıflandırma Sonuçları.....	26
4.3 Geliştirilen Modelin Diğer Derin Öğrenme Modelleri ile Karşılaştırılması.....	29
5. SONUÇLAR VE ÖNERİLER	33
KAYNAKLAR.....	35
ÖZGEÇMİŞ	38

ÇİZELGELER DİZİNİ

Çizelge 2.1: Yaygın bilinen aktivasyon fonksiyonları.....	12
Çizelge 3.1: Veri setindeki sınıflar ve sınıflarda bulunan örnek sayıları.....	19
Çizelge 3.2: Tezde kullanılan Alzheimer veri setini kullanarak yapılmış olan literatür çalışmaları.....	21
Çizelge 3.3: Geliştirilen beş farklı derin öğrenme modelindeki özel blok yapılarının kullandıkları mimariler.....	22
Çizelge 4.1: Önerilen beş modelin sınıflandırma sonuçlarına ait metrikler	27
Çizelge 4.2: Önerilen modeller ile güncel modellerinin sınıflandırma sonuçları	30



ŞEKİLLER DİZİNİ

Şekil 1.1: Sağlıklı beyin ve AH' li beyin karşılaştırılması.	3
Şekil 1.2: Aksiyal, Koronal ve Sagittal düzlem MRG görüntü örnekleri [8]	4
Şekil 2.1: Evrişim katmanında evrişim sürecinin örnek gösterimi.	10
Şekil 2.2: Havuzlama işlemi ile ilgili örnek gösterim.	11
Şekil 2.3: Yukarı örnekleme katmanı.....	11
Şekil 2.4: Artık bağlantı modeli.	14
Şekil 2.5: Dense blok yapısı [36].	16
Şekil 2.6: VGGNet mimarisinin temel yapısı [38].	17
Şekil 2.7: Inception modelinin modül yapısı [39].....	18
Şekil 3.1: Alzheimer Veri Kümesi Sınıfları Örnekleri.....	20
Şekil 3.2: Tez çalışmasında geliştirilen özel blok yapıları derin öğrenme modeli	24
Şekil 4.1: Karmaşıklık matrisi.	25
Şekil 4.2: Geliştirilen modellere ve karşılaştırmada kullanılan yöntemlere ait ROC eğri grafikleri.	32

SEMBOLLER VE KISALTMALAR

AD	: Alzheimer's Disease
ADNI	: Alzheimer Hastalığı Nörogörüntüleme Girişimi
AH	: Alzheimer Hastalığı
B	: Boyut
BN	: Batch Normalizasyon
BT	: Bilgisayarlı Tomografi
D	: Derinlik
DAE	: Derinlemesine Ayrılabilir Evrişim
DE	: Derinlemesine Evrişim
DVM	: Destek Vektör Makinaları
ESA	: Evrişimsel Sinir Ağı
H	: Yükseklik
HBB	: Hafif Bilişsel Bozukluk
KNN	: K-en Yakın Komşuluk
MID	: Hafif Demans
MOD	: Orta Demans
MRG	: Manyetik Rezonans Görüntüleme
NOD	: Demansız
OASIS	: Açık Erişim Görüntüleme Çalışmaları Serisi
P	: Dolgulama (Padding)
PET	: Pozitron Emisyon Tomografi
ROC	: Receiver Operating Characteristic
TÖ	: Transfer Öğrenme
VMD	: Çok Hafif Demans
W	: Genişlik
YÖ	: Yukarı Örnekleme
YSA	: Yapay Sinir Ağı
<i>pb</i>	: Parça Boyutu
<i>fb</i>	: Filtre Boyutu
<i>fs</i>	: Filtre Sayısı
<i>ad</i>	: Adım Genişliği

ÖZET

Yüksek Lisans Tezi

MANYETİK REZONANS GÖRÜNTÜLERİNDE ALZHEİMER HASTALIĞININ TESPİTİ İÇİN YENİ DERİN ÖĞRENME MODELLERİNİN GELİŞTİRİLMESİ

Eyup HANBAY

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

38 + VIII sayfa

2023

Danışman: Dr. Öğr. Üyesi Ali ARI

Nörolojik bir rahatsızlık olan Alzheimer hastalığı genellikle yaşlı bireyleri etkilemektedir. Bu hastalık erken teşhis edilerek bazı önleyici ve hasta konforunu iyileştirici tedbirler alınabilmektedir. Bu noktada yapay zekâ ve görüntü işleme yöntemlerinin kullanılması ile etkin hastalık tespit yöntemleri geliştirilmiştir. Bu tez çalışmasında Alzheimer hastalığının 3 evresini içeren bir Alzheimer MRI veri seti kullanılarak hastalık evrelerini tespit eden derin öğrenme tabanlı yöntemler geliştirilmiştir. Geliştirilen yöntemlerde derin öğrenme mimarileri kullanılmaktadır. Geleneksel evrişim katmanı, ResNet50 ve InceptionV3 mimarileri birlikte kullanılarak 5 farklı derin öğrenme modeli geliştirilmiştir. Özellikle Resnet50 ve InceptionV3 mimarilerinin özel blok yapılarının üstün yönleri birlikte çalışacak şekilde optimize edilerek hibrit derin öğrenme modelleri geliştirilmiştir. Modellerin katman yapısı Alzheimer verilerini yorumlayacak şekilde optimize edilmiştir. Model tasarımları kaybolan gradyan problemi göz önünde bulundurularak yapılmıştır. Ayrıca özel blok yapılarının sıralamasında ve modellenmesinde aşırı öğrenme ve hesapsal karmaşıklık gibi istenmeyen durumlar göz önünde bulundurulmuştur. Geliştirilen yöntemler, güncel derin öğrenme yöntemleri ile farklı performans metrikleri kullanılarak karşılaştırılmıştır. Deneysel sonuçlar geliştirilen metotların etkin sonuçlar elde ettiklerini göstermektedir.

Anahtar Kelimeler: Alzheimer hastalığı tespiti, derin öğrenme, Inception, ResNet.

ABSTRACT

Master Thesis

DEVELOPMENT OF NEW DEEP LEARNING MODELS FOR DETECTION OF
ALZHEIMER'S DISEASE IN MAGNETIC RESONANCE IMAGES

Eyup HANBAY

Inonu University

Graduate School of Nature and Applied Sciences
Department of Computer Engineering

38 + VIII page

2023

Supervisor: Dr. Öğr. Üyesi Ali ARI

Alzheimer's disease, which is a neurological disorder, usually affects old people. This disease can be diagnosed early and some preventive measures can be taken to improve patient comfort. At this point, effective Alzheimer disease detection methods have been developed with the use of artificial intelligence and image processing methods. In this thesis, deep learning-based methods were developed to detect disease stages by using an Alzheimer MRI dataset containing 3 stages of Alzheimer's disease. The developed methods use deep learning architectures. By using conventional convolution layer, ResNet50 and Inception V3 architectures together, 5 different deep learning models have been developed. In particular, hybrid deep learning models have been developed by optimizing the special block structures of the Resnet50 and Inception V3 architectures to work together. The layer structure of the models has been optimized to interpret Alzheimer's data. Model designs are made by considering the vanishing gradient problem. In addition, undesirable situations such as over fitting and computational complexity are taken into account in the ordering and modeling of special block structures. The developed methods are compared with current deep learning methods using different performance metrics. The experimental results show that the developed methods have obtained effective results.

Keywords: Alzheimers's disease detection, deep learning, Inception, ResNet.

1. GİRİŞ

1.1 Alzheimer Hastalığı (AH)

Alzheimer rahatsızlığı Dr. Alois Alzheimer tarafından keşfedilmiştir. Dr. Alois Alzheimer zihinsel hastalıkların sebep olduğu ölümleri inceleyerek, bu ölümlere ait kadavra beyinlerindeki sinir yapılarını incelemiş ve bu duruma sebep olan hastalığı keşfetmiştir [1]. İlk kez nörolojik hasar ve bundan kaynaklı ölümlere beyin hücrelerinin ölmelerinin sebep olduğu tezini savunmuştur. Daha sonraki çalışmalarında bu hastalığa ait tedaviler geliştirmiştir. Beyindeki hücrelerin ölümleri ile beyin küçülmesi Alzheimer Hastalığının (AH) ilk bulgularıdır. Hastalarda yakınmalar hafıza kaybı ile başlar. Zaman geçtikçe hastalığın belirtileri demans (bunama) şeklinde gözlemlenirken, son olarak da günlük hayatı başkalarının güç ve yardımı olmaksızın idame ettiremeyecek seviyeye getirmektedir [2]. AH semptomları genellikle yavaş yavaş ortaya çıkar. Beyindeki moleküler ve hücrenel olumsuz değişimler hastalarda hatırlama geriliği, karar verme yetisini yitirme ve bilişsel kargaşaya sebep olarak gündelik hayatsal faaliyetlerini yerine getiremez hale getirmektedir. Beynin yapısındaki değişikliklere bakılarak; hastalığa sebep olan bir etken mi yoksa hastalığın neden olduğu bir sonuç mu olduğu belirsizliğini devam ettirmektedir. Bunamaya en çok sebep olan AH aynı zamanda en yaygın nöropsikiyatrik rahatsızlıktır. Dünya üzerinde 2015 yılında yaklaşık 50 milyon demans hastası olduğu bilinmektedir. Hasta sayısının aradan geçecek 35 yıl içinde 3 katına yaklaşacağı öngörülmektedir [3]. Farklı bir çalışmada ise Alzheimer hastalığının, 2060 yılına kadar ABD'de 14 milyon insanı etkileyeceği savunulmaktadır [4]. Demans hastalarının yarısından fazlası AH hastalığına dönüşmektedir ve ileri yaşlarda AH görülme olasılığı daha da yükselmektedir. Ülkemizde Türkiye İstatistik Kurumu (TÜİK) 2023 yılında 65 yaş üzerindeki nüfusun 8,6 milyon kişiye ulaşacağını projeksiyonlarında belirtmektedir. Buna bağlı olarak AH sayısında artış kaçınılmaz olacaktır.

1.1.1 Alzheimer hastalığı ve semptomları

İnsan beyni de vücudun diğer organları gibi yaşlandıkça yapısal ve işlevsel değişikliklere uğrarlar. Beynin oluşumu doğumdan sonra çok hızlı şekilde başlar. 3 yaşına geldiğinde % 80 tamamlanmış olur. Geri kalan oran ise ileriki yaşlarda tamamlanır. Yaş ilerledikçe ölen beyin hücrelerinin yerine yenileri gelmez. Beynin öğrenmeden sorumlu alanında başlayan anormal bozulmalar AH hastalığının ilk belirtileridir. Bu semptom yeni

öğrenilen bilgilerin hatırlanamamasına sebep olur. Hastalık ilerledikçe bireyde sinir, saldırganlık, etrafındakilere güvensizlik gibi davranış değişikliği bunların sonucunda sosyal çekilme ve depresyon ve yönelim bozukluklarına sebep olur. İleri evrelerde artık hasta yutma, konuşma, yürüme gibi yaşamsal faaliyetlerini sürdüremez ve bunun yanında ciddi olarak hafıza kaybına maruz kalırlar.

1.1.2 Alzheimer hastalığı evreleri

AH hastalığı Erken, Orta ve İleri seviye evreleri olarak sınıflandırılmaktadır. Aynı zamanda Klinik Öncesi, Hafif Bilişsel Bozukluk ve Demans evreleri olarak da isimlendirilmektedir [3]. Şu ana kadar kesin bir tanı ve tedavisi bulunamamış olan AH beynin farklı kısımlarını etkisi altına alarak ilerleyen nörodejeneratif bir rahatsızlıktır.

A. Erken (Klinik Öncesi) Evre: Bu evrede kişi günlük hayatını bir başkası tarafından yardıma ihtiyaç duymadan sürdürebilirken, isim ve adres gibi en temel bilgileri hatırlayamaz. Hastalığın erken evresi yıllara yayılabilir. Bu aşamada dikkat çekecek klinik bir belirti göstermeyebilir. Fakat klinik imkanlardan faydalanılarak erken evre durumu tespit edilebilmektedir. Biyomedikal alanındaki gelişme yeni görüntüleme teknolojileri sayesinde beyindeki bazı proteinlerin arttığı saptanmıştır. Beta-amiloidler AH diğer hastalıklardan ayıran bulgu olarak karşımıza çıkmaktadır.


B. Orta (Hafif Bilişsel Bozukluk) Evre: Hafif Bilişsel Bozukluk (HBB) bireyin yaşıtlarına nazaran daha fazla unutkanlık yaşaması ile ortaya çıkar. Bireyin insan ilişkilerinde ve işindeki yetkinliğini önemli oranda etkilemez. Bu evre aynı zamanda AH' nin başlangıcı olarak da kabul edilmektedir. Klinik öncesi evreden farklı yanı git gide kötüleşen semptomlar önlem alınmadığında birkaç yıl içinde demansa dönüşebilmektedir [5]. Önlem olarak ilaç tedavisi, bunun yanında psikoterapi evrenin ilerleyişini yavaşlattığı gibi yaşam kalitesini yükseltir. Klinik öncesi evrede teşhis için kullanılan görüntüleme teknolojileri HBB içinde yardımcı olarak geçerli sonuçlar vermektedir. HBB uzman bir nöroloğun bulguları inceleyip profesyonel değerlendirmeleri sonucu teşhis edebilmektedir.

C. İleri (Demans) Evre: Demans evresinde hastalar semptomların şiddetlendiği için günlük yaşantılarında kendi kendilerine yetemedikleri görülür. Kişilik ve davranış bozuklukları hastaları tamamen etkisi altına alır [6]. Birey artık etrafındakiler ile etkileşimini yitirir. Yeme, içme ve yürüme gibi işlevleri tek başına yapamaz. Beyin hücrelerindeki ölümler ve bozulmalar beynin bütün bölgelerine yayıldığı için vücuttaki

istemsiz kontrollerde ortadan kalkarak hastayı yaşam destek ünitelerinde bitkisel hayata zorlar.

1.1.3 Alzheimer hastalığı tanı teknikleri

Alzheimer hastalığı beynin öğrenmeden sorumlu ön kısımlarında ve hipokampus bölümünde başlar daha sonra konuşma, düşünme, sosyal faaliyetlerin kontrol edildiği diğer bölümlerden olan serebral korteksi ile ventrikülleri de etkisi altına alarak büzüşme ve genişleme şeklinde gözlemlenmektedir. Beynin yapısında gözlemlenen ölümlerden ve tedavisi olmayan hasarlara; normal olmayan plaka ve yumak değişiklikleri sorumlu tutulmaktadır [7]. Plakaların diğer bir ismi Beta-Amiloidler vücutta doğal olarak üretilen protein parçalarıdır. Beyinde bulunan büyük proteinlerin enzimler ile parçalanması sonucu yapışkan yapıdaki beta-amiloidler oluşur. AH' li beyindeki bu değişimler Bilgisayarlı Tomografi (BT) ve Manyetik Rezonans Görüntüleme (MRG) gibi nörolojik görüntüleme teknikleri ile de gözlemlenebilmektedir. Sağlıklı beyin ve AH' li beyine ait koronal düzlem görüntülerin karşılaştırılması Şekil 1.1 de verilmiştir.



Şekil 1.1: Sağlıklı beyin ve AH' li beyin karşılaştırılması.

Hastalığın teşhis edilebilmesi için farklı görüntüleme teknikleri kullanılmaktadır. Nörogörüntüleme tekniklerindeki gelişmeler hastalığın teşhisinde ve tanı koymada başarıyı arttırmıştır.

Manyetik rezonans görüntüleme (MRG): Yapısal bir görüntüleme tekniği olan MRG canlı beyin ve omurilik gibi yumuşak doku merkezi sinir sistemi hastalıklarının tespitinde yüksek çözünürlüklü görüntüleme sağladığı için tercih edilir. MRG cihazlarında görüntüleme üç boyutlu (3B) yapılabilmektedir. Aksiyel, Koronal ve Sagittal olarak üç düzlemde siyah beyaz renklerden oluşan görüntüler alınabilmektedir.



Şekil 1.2: Aksiyal, Koronal ve Sagittal düzlem MRG görüntü örnekleri [8]

MRG cihazları vücuttaki organ ve dokulara herhangi bir zarar vermeyen manyetik alan ve radyo dalgalarını kullanırlar. Güçlü bir manyetik alan geçici olarak görüntülenecek dokudaki hidrojen atomlarına etki ederler. Radyo dalgaları da bu etkileşimdeki atomların çok zayıf sinyaller üretmesini sağlarlar, buna bağlı olarak gözlemlenen değişiklikler ile çalışılan organın kesit MRG görüntüleri oluşturulur. Dokunun özelliğine göre çözünürlük ve parlaklık sağlamak için T1, T2 ve FLAIR gibi MRG sekans çeşitleri vardır.

Bilgisayarlı tomografi (BT): AH teşhis etmede faydalanılan görüntüleme yöntemlerinden bir diğeridir. BT görüntülenecek organ veya doku etrafında döndürülen X-ışını hüzmeleri bilgisayarların işleyebileceği sinyallere dönüştürülerek çıktı üretilir [9]. Röntgene göre daha detaylı görüntüleme sağlarlar. Beynin dokusundaki kayıplar ve beyin sıvı miktarı hakkında bilgi edinmek için başvurulan bir yöntemdir. Beyin hücrelerinin ölmesi ile dokulardaki kaybı tespit etmek için MRG ye göre daha kolay uygulanabilse de MRG daha çok tercih edilmektedir.

Pozitron emisyon tomografisi (PET): Tıbbi görüntüleme tekniklerinden biri olan PET hücre düzeyinde uzmanlara, sistemik kompleks hastalıkların teşhisi ve kesin tanısında yardımcı olmaktadır. Organ ve dokularda kan akışı, oksijen miktarı gibi detay bilgi olan metabolik olayların incelenmesini sağlar. PET uygulanacak hastalara önce radyofarmasötik ilaçlar enjekte edilir. Bu radyoaktif izleyiciler içeren ilaç yoğun kimyasal aktiviteye sahip dokular tarafından emilirler. İlaç içindeki radyoaktif izleyicilerin elektron ve pozitronları birbirlerini yok ederek gama dalgaları saçarlar. Saçılan ışınlar emildiği dokunun görüntülenmesini sağlar. Taramadan elde edilen renk ve parlaklığın derecelerine göre dokudaki fonksiyon farklılıkları irdelenmiş olur.

1.2 Literatürde Yapılan Çalışmalar

Alzheimer hastalığının tanı ve tedavisinde doktorlara katkı sunacak akıllı yöntemler zaman içerisinde geliştirilmiştir. Böylece tanı koyucuların daha hassas ve sayısal değerlere dayalı hastalık teşhisi yapmalarına olanak sağlanmıştır [10]. Çeşitli görüntüleme teknikleri ile elde edilen beyin görüntüleri uygun ön işlem adımları ve özellik çıkarma yöntemleri ile işlenmeye hazır hale getirilmektedir. Özellikle görüntülerdeki gürültü kaynaklı istenmeyen bileşenlerin ortadan kaldırılması ile makine öğrenmesi yöntemlerinin daha sağlıklı çalışmaları sağlanmıştır. Hem geleneksel makine öğrenme yöntemleri hem de derin öğrenme tabanlı öğrenme yöntemleri ile Alzheimer hastalığını tespit edebilen birçok yöntem geliştirilmiştir [11].

Menagadevi ve diğ. [12] çok ölçekli havuzlama kalıntı (residual) otomatik kodlayıcı ve Destek Vektör Makinesi yöntemlerini birlikte kullanarak Alzheimer hastalığını tespit eden bir yöntem geliştirmişlerdir. Veri seti olarak Kaggle'dan elde edilen veri seti ile ADNI veri setini kullanmışlardır.

Önerilen bir CNN+Softmax modelinde ise kullanılan veriler özellik çıkarma işlemi öncesinde iyileştirilmiştir [13]. Görüntüler 150x150 piksel boyutuna ayarlanarak gürültü giderme işlemi yapılmıştır. Böylece modelin başarısı artmıştır.

Cheung ve diğ. [14] Alzheimer hastalığı-demansı tespit etmek için retinal fotoğraf tabanlı bir derin öğrenme algoritması geliştirdi. Önerdikleri model için 648 Alzheimer hastası ve 3240 hasta olmayan kişiden alınan 12949 retina fotoğrafı kullanmışlardır. Model %93,2 doğruluk başarısı elde etmiştir.

Kaggle'dan elde edilen bir veri tabanı üzerinde yapılan çalışmada transfer öğrenme tabanlı bir hastalık tespiti yöntemi geliştirilmiştir [15]. Nümerik kararlılık sağlamak için veriler normalize edilmiştir. Parlaklık değişimi ve yatay/dikey atlama yöntemleri ile mevcut MRG verileri üzerinde veri arttırımı yapılmıştır. Ağ modeli Adam optimizasyon algoritması ile optimize edilmiştir. Yöntem genel olarak başarılı olmakla birlikte, farklı veri formatlarında kısıtlılıklar içermektedir.

Denetimli ve denetimsiz öğrenme modelleri veri sınıflandırmada yoğun şekilde kullanılmaktadır [16]. Bu modellerin hiper parametreleri optimize edilerek Alzheimer hastalık evrelerini tespit eden bir çalışmada denetimli karşıt (contrastive) öğrenme ve denetimsiz karşıt öğrenme metodolojileri ile ortalama %92 başarı elde edilmiştir. Bu yöntemler ResNet100 ve EfficientNetB2 derin öğrenme mimarileri ile de kıyaslanmıştır.

Sathish Kumar ve diğ. [17] yaptıkları çalışmada Alzheimer hastalığını hafif bilişsel bozukluk evresinde tespit etmeye yönelik %98,35 doğruluk sağladıkları yaklaşım sunmuşlardır. Önerdikleri model önceden eğitilmiş AlexNet ağına Açık Erişim Görüntüleme Çalışmaları Serisi (OASIS) Beyin veri setinden elde ettikleri 5000 den fazla MRG verisi kullanmışlardır.

Tian Bai ve diğ. [18] Alzheimer hastalık kategorisini tahmin etmek için yeni üç bileşenli çekişmeli ağ tabanlı Alzheimer belirleme yöntemi önermişlerdir. BSGAN-ADD adı verilen bu yöntem üretken çekişmeli ağ (GAN) tabanlı beyin dilimi görüntü geliştirme yöntemi ile ESA (Evrişimli Sinir Ağı) tabanlı Alzheimer algılamayı birleştirir. BSGAN-ADD yönteminde öğrenme algoritması sınıflandırıcıdan gelen hastalık kategorisi geri bildirimlerini kullanarak, eğitim aşamasında görüntü iyileştirme yapar. Böylece 2 boyutlu beyin dilimi görüntüsünü yeniden yapılandırma sürecine entegre etmiş olur.

Kong ve diğ. [19] Alzheimer teşhisi için MRG ve PET resimlerini birleştiren bir füzyon birleşme tekniği kullanmışlardır. Füzyon tekniği ile beyinin anatomik ve metabolik bilgilerine odaklanarak parazitlerden arındırmışlardır. Önerdikleri resim birleştirme yönteminin üç boyutlu evrişimli sinir ağı ile tek boyutlu resim kullanarak sınıflandırma yapan diğer yöntemlere göre daha başarılı sonuçlar verdiğini doğrulamışlardır.

Kapadnis ve diğ. [20] yaptıkları derleme çalışmada yapay zeka ve derin öğrenme kullanarak Alzheimer tespiti yapan çalışmaları değerlendirmişlerdir. Özellik çıkarma yöntemlerinin etkinlikleri, zayıf/güçlü yönleri ve gelecekte yapılabilecek çalışmaları irdelemişlerdir.

Diğer bir derleme çalışmasında ise 3 boyutlu ESA mimarileri ile 2 boyutlu ESA mimarilerini karşılaştırarak farklı ESA modellerinin Alzheimer tespitindeki yetenekleri incelenmiştir [21]. 3 boyutlu ESA modelleri ile nörogörüntüleme modalitelerinin birlikte kullanımının alzheimer tanısındaki katkıları sunulmuştur. Özellikle gelecekte bu ikili kullanımın hastalık tespitinde faydalı olacağı vurgulanmıştır.

Lanjewar ve diğ. K-en yakın komşuluk (KNN) algoritması ve ESA mimarisini kullanarak 6400 MRI görüntüsünden Alzheimer hastalık türlerini tespit etmişlerdir [22]. Çalışmalarında orta demanslı, hafif demanslı, çok hafif demanslı ve demanssız olmak üzere 4 tip Alzheimer hastalık evresini sınıflandırmışlardır. KNN modelini eğitmek ve doğrulamak için veri setinden özellik çıkarma işlemi yapılmıştır. Bu çalışmanın ortalama doğruluğu %99,58 olup F1 skoru ise %99,43'tür.

Destek vektör makineleri sınıflandırıcısı kullanılarak 3'ü farklı Alzheimer hastalık evrelerine ve biri de sağlıklı olmak üzere 4 sınıflı veri seti üzerinde hastalık tespiti yapılmıştır [23]. Veri setindeki görüntüler farklı görüntü iyileştirme ve ön işleme yöntemleri ile gözden geçirilerek yöntemlerin başarısı izlenmiştir. İyileştirilen MRG verileri VGG16 derin öğrenme mimarisi ile sınıflandırılarak görüntü iyileştirme yöntemlerinin de performansları karşılaştırılmıştır.

ResNet50 derin öğrenme modeli temel alınarak bu mimariye eklenen dikkat mekanizmaları ile Alzheimer hastalık evreleri sınıflandırılmıştır [24]. Çoklu paralel evrişim katmanları, havuzlama ve dikkat katmanları ile ağır performansı hastalık evrelerini içeren veri seti görüntülerine göre hassaslaştırılmıştır. Özellikle mimariye entegre edilen genişletilmiş (dilated) evrişim modeli ile veri özellikleri soyutlanırken bilgi kaybı önlenmiştir.

Yürütülen hibrit bir çalışmada transfer öğrenme ve permütasyon makine öğrenmesi yöntemleri birlikte kullanılarak Alzheimer teşhisi yapabilen bir yöntem geliştirilmiştir [25]. DenseNet-121 ve DenseNet-201 modelleri özellik çıkartmada transfer öğrenme modelleri olarak kullanılmıştır. Destek vektör makineleri, Gaussian naïve ve XGBoost sınıflandırıcılardan faydalanılarak etkin sonuçlara ulaşılmıştır.

Alzheimer hastalığını teşhis etmek için PET ve MRG verilerinden gelen heterojen bilgileri birleştiren ve MultiAz-Net olarak adlandırılan derin sinir ağı öğrenme modeli geliştirilmiştir [26]. Birleştirilmiş verilerden çıkarılan özelliklere dayanarak, Alzheimer hastalığının başlangıcını erken bir aşamada tahmin etmek için otomatik bir prosedür geliştirilmiştir. Önerilen yöntem görüntü birleştirme, özellik çıkarma ve sınıflandırma olmak üzere 3 temel aşamadan oluşmaktadır. Ayrıca Çok Amaçlı Çekirge Optimizasyon Algoritması (MOGOA), MultiAz-Net'in katmanlarını optimize etmek için kullanılmıştır.

Güncel bir çalışma da 2 boyutlu T1 ağırlıklandırılmış MRG verileri kullanılarak orta demanslı, hafif demanslı, çok hafif demanslı ve demanssız beyin görüntüleri ESA mimarisi ile ayırt edilmiştir [27]. MRG verilerini gürültüden arındırmak için piksel tabanlı çarpma faktörü kullanılmıştır. Eğitim işlemi öncesinde gri ölçekteki veriler 150x150 boyutuna ayarlanmıştır. ESA mimarisinin tüm bloklarında ReLU aktivasyon fonksiyonu, 0,001 öğrenme oranı ve maksimum 100 Epoch değeri kullanılmıştır. Geliştirilen yöntem DenseNet121, ResNet50, VGG16, EfficientNetB7, ve InceptionV3 modelleri ile karşılaştırılmıştır. Önerilen yöntemin başarısı %99,68'dir.

Alzheimer teşhisi için ayırt edilebilir özellikler sağlayan beyin kanıtlanmış yer işaretlerini analiz etmek amacı ile yapılan bir çalışmada hem sol hem de sağ hipokampus bölgelerine odaklanılmıştır [28]. Sol ve sağ hipokampus bölgesi manuel olarak lokalize edilmiştir. Ön işleme adımlarından sonra ESA mimarisine 3 görüntü yaması verilmiştir. ESA mimarisi burada özellik çıkarıcı olarak kullanılarak softmax sınıflandırıcı ile veriler sınıflandırılmıştır. Kullanılan veriler GARD veri tabanından alınmıştır. %90,05 sınıflandırma doğruluğuna ulaşılmıştır. Bununla birlikte beyinin sol ve sağ hipokampus bölgesinin manuel bir şekilde lokalize edilmesi zor bir işlem olup bu yöntemin zayıf noktasıdır.

Seifallahi ve diğ. [29] zamanlanmış “kalk ve yürü testi” adı verilen basit bir denge ve yürüme değerlendirme testini kullanarak Alzheimer hastalığını tespit etmişlerdir. Kinect V.2 kamera kullanarak 47 sağlıklı, 38 Alzheimer hastası bireyin ortak konum verileri toplanmıştır. 12 önemli özellik ile denge ve yürüyüş analizi yapılarak destek vektör makineleri (DVM) yardımı ile sınıflandırma yapılmıştır. Ortalama doğruluk %97,75 olarak elde edilmiştir. Bu çalışmanın önemli yanı Alzheimer tespiti için Kinect kamera ile makine öğrenmesi yöntemlerinin birlikte kullanılmış olmasıdır.

Khan ve diğ. [30] güncel bir VGG mimarisi kullanarak ADNI veri tabanı üzerinde Alzheimer hastalığını tespit etmişlerdir. Veri tabanındaki görüntülerin en bilgilendirici olanlarını seçmek için görüntü entropisini kullanmışlardır. Ayrıca ayırt edici görüntü bölgelerine odaklanmak için sınıf aktivasyon haritaları kullanmışlardır. Böylece VGG mimarisinin farklı Alzheimer evrelerini tanıyabilmesine katkı sunulmuştur.

1.3 Tezin Amacı

Bu tezde Alzheimer hastalığının tespiti için yeni hibrit derin öğrenme modellerinin geliştirilmesi amaçlanmıştır. Mevcut derin öğrenme modellerinin özel blok yapıları incelenerek birlikte aynı modelde çalışabilecek mimariler incelenmiştir. Böylece her bir modelin güçlü yanı diğer modellerle birlikte kullanılacak şekilde optimal derin öğrenme mimarileri geliştirilmiştir. Aşırı öğrenme ve kaybolan gradyan problemine yol açmayacak şekilde derin öğrenme mimarileri tasarlanarak Alzheimer hastalık tespitinde literatüre katkı sağlayacak çalışmalar yapılması amaçlanmıştır. Bununla birlikte geliştirilen mimarilerin çok kullanılan derin öğrenme mimarileri ile performanslarının karşılaştırılması ve yorumlanması da tezin önemli amaçları arasındadır.

2. DERİN ÖĞRENME

Bilgisayarların veri işleme gücündeki ilerleme ile insan müdahalesinden bağımsız çok karmaşık problemleri çözmek için; Yapay Sinir Ağlarına (YSA) dayalı makine öğrenmesi alt algoritması olan derin öğrenme yöntemi önerilmiştir [31], [32]. Bu yöntem insan beyninin işlev ve çalışmasından esinlenilerek geliştirilmiştir.

Derin öğrenme uygulanan problemlerde; ham verilerden otomatik olarak özellik çıkarımı yapılarak istenilen sonuçlar elde edilmektedir. Derin öğrenmeyi Yapay Sinir Ağlarından ayıran temel özellikler çıkış değerlerine ulaşmak için kullanılan birbirini izleyen katmanlar arasındaki bağlantı şekli ve kullanılan parametre sayısıdır. Modelin eğitimi sırasında sayısı milyonları bulan bu parametreler; ileri ve geri yayılım işlemleri ile güncellenerek en doğru değerleri alması sağlanır. Çok yüksek seviyede işlem gerektiren hesaplamalar için her ne kadar bu yöntemde dezavantaj olsa da günümüz bilgisayar donanımı ve yazılım alanındaki gelişmeler sayesinde veri işleme çok kolaylaşmıştır.

Derin öğrenmede en çok kullanılan ve bilinen iki modelden biri olan Evrişimli Sinir Ağları (ESA) bir sınıflandırma algoritmasıdır [33]. Görüntü sınıflandırma ile nesnenin olasılığını tahmin etmenin yanında konumlama problemlerinde nesnenin olasılığını ve bulunduğu yeri de tahmin eder. ESA algılama problemlerinde görüntüdeki birden fazla nesneyi algılar, nesnelerin olasılıklarını ve nerede olduklarını tahmin için kullanılırlar. ESA yapı ve işleyiş yönünden farklı katmanların farklı sıralamalar ile arka arkaya bağlanmasıyla oluşturulmaktadır. Mimari olarak üç ana bölümden meydana gelmektedir: Giriş kısmı, özniteliklerin belirlendiği gizli katmanlar ve son olarak sınıflandırma işleminin yapıldığı çıkış kısmıdır. Modüler olan bu gizli katmanlar girişte verdiğimiz ham veriler üzerinde kendi operasyonlarını gerçekleştirerek sonuca katkı sağlamaktadırlar. ESA'lar tek boyutlu verilerin yerine çok boyutlu verileri kullanırlar ve sonuçta daha fazla başarı sağlarlar. Yeni bir problem için önceden eğitilmiş bir ağın parametre değerlerini kullanmak getirdiği avantajlardandır. Bu sayede ağı sıfırdan eğitmek için zaman ve enerjiden tasarruf edilir. ESA modelleri sınıflandırma problemlerinde farklı değerlerde filtre kullanarak görüntü niteliklerini tanımlayabilmek ve ayırt edebilmek için özellik haritaları çıkarırlar.

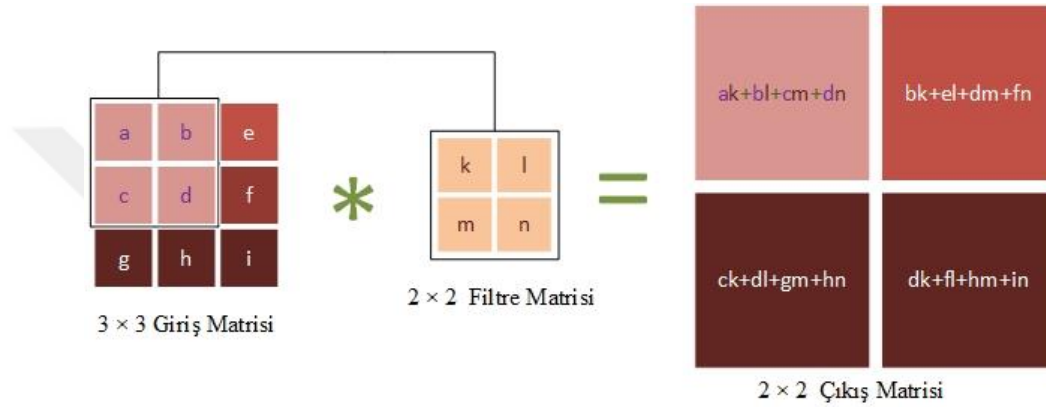
2.1 Evrişimsel Sinir Ağlarının (ESA) Bileşenleri:

Bu bölümde tez çalışmalarında kullanılan derin öğrenme modellerinin temellerinden olan evrişimli sinir ağları ile ilgili temel tanımlamalara ve bilgilere yer

verilmiştir. Böylece derin öğrenme modellerinin çalışma prensipleri, özellik çıkartma metotları ve katman yapıları hakkında bilgi sahibi olunması amaçlanmıştır.

2.1.1 Evrişim katmanı

Evrişim Katmanı, Evrişimsel Sinir Ağlarının en temel yapı taşı ve görüntünün ele alındığı ilk katmandır. Üzerinde işlem yapılacak görüntü ve görüntünün çözünürlüğüne bağlı olarak bir piksel dizisi olarak belirli aralıktaki değerlerden oluşan matrislerdir. Evrişim katmanında görüntü matrisi üzerinde daha küçük boyuttaki çok boyutlu filtreler uygulanarak görüntüdeki düşük ve yüksek seviyeli özellikler çıkartılmaktadır.



Şekil 2.1: Evrişim katmanında evrişim sürecinin örnek gösterimi.

Şekil 2.1’ de, tek boyutlu ve 3x3 boyutlu görüntü matrisine 2x2 boyutlu filtresinin uygulanması ve elde edilen çıkış matrisi (2x2 boyutlu) verilmiştir. Burada gösterildiği gibi i, j, k, l ağırlıklarına sahip 2x2 filtre giriş matrisine uygulanarak 2x2 boyutlu çıktı matrisi elde edilmiştir. Bu örnekte giriş için 3x3 ve filtre için 2x2 boyutunda matrisler evrişim işlemine tabi tutulmuş, 1 basamak kaydırmayla çıkış matrisi sonuçta 2x2 olmuştur. Çıkış matrisinin boyutunu giriş ve uygulanan filtre matrisi boyutu belirlemektedir.

$$O_w = \frac{I_w - F_w + 2P}{S} + 1$$

$$O_h = \frac{I_h - F_h + 2P}{S} + 1 \quad (2.1)$$


$$\text{Çıkış boyutu} = O_w \times O_h$$

2.1’ de denklemlerdeki O_w ve O_h : sırası ile çıkış matris genişliği ve yüksekliği, I_w ve I_h sırası ile giriş matrisi genişlik ve yüksekliği, F_w ve F_h sırası ile filtre matris genişlik ve yüksekliği S adım sayısı, P ise dolgu sayısıdır.

2.1.2 Havuzlama katmanı

Bu yöntem ile görüntü matrisi üzerinde belirlenen ölçülerde bir pencere dolaştırılır. Dolaştırılan pencere içinde kalan kısımda her bir adımda belirlenen kurala göre (maksimum, minimum, ortalama) elde edilen sonuç tek bir değere dönüştürülmektedir. Havuzlama işlemi ESA içindeki parametre ve hesaplama miktarını düşürmektedir [34]. Görüntüyü temsil eden matrisin boyutu azaltılır. Gereksiz özellikler yok sayılarak daha önemli özelliklere ön plana çıkartılır.

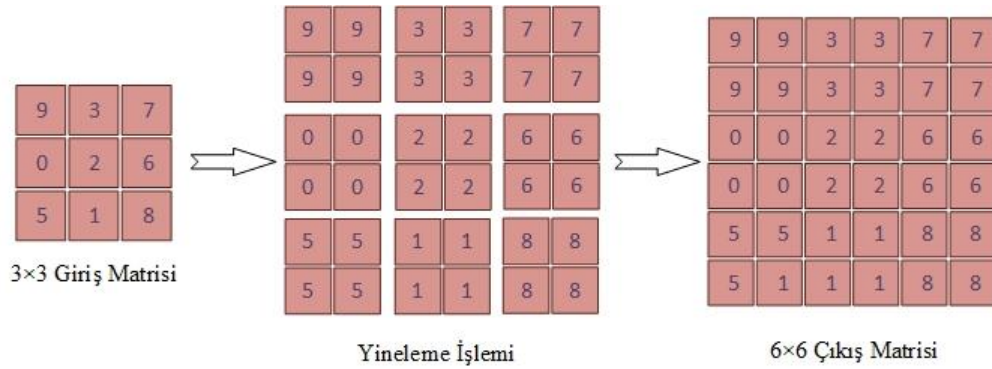
Havuzlama katmanı ile ilgili 3×3 lük giriş matrisine 2×2 lik maksimum havuzlama yönteminin uygulanması ile ilgili örnek bir gösterim Şekil 2.2’te verilmiştir.



Şekil 2.2: Havuzlama işlemi ile ilgili örnek gösterim.

2.1.3 Yukarı örnekleme katmanı

Havuzlama katmanında yapılan işlemin aksine giriş matrisinin boyutunu arttırmak için kullanılır. U-Net mimarisi kodlayıcı-kod çözücü bir ağ mimarisine sahip olup piksel seviyesinde sınıflandırma yapmaktadır. Bu mimaride giriş ile çıktı katmanındaki veri boyutu aynıdır. Bu tür mimarilerde yukarı örnekleme katmanı kullanılarak özellik verisinin boyutu artırılabilir. Yukarı örnekleme katmanının uygulanışı ile ilgili görsel bilgilendirme Şekil 2.3’te sunulmuştur.

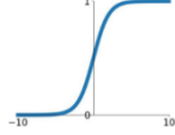
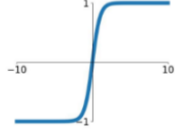
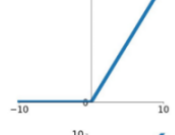
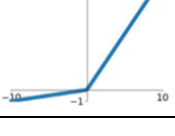


Şekil 2.3: Yukarı örnekleme katmanı.

2.1.4 Aktivasyon fonksiyonu

ESA'larda gerekleřtirilen nemli dięer bir iřlemde aktivasyon fonksiyonunun kullanımıdır. Evriřim iřlemi doęrusal bir iřlemdir; doęrusal fonksiyonun doęrusal olmayan bir fonksiyonla etkileřimi katman ıktılarına doęrusalsızlık zellięi kazandırır. Bu iřleme aktivasyon iřlemi denir [33]. Aktivasyon sayesinde katmanların birbirlerine olan baęımlılıęı azaltılarak ESA mimarilerinin tutarlılıęının artması saęlanır. Sinir aęının eęitim srecinde aęırlıklar eřitli optimizasyon teknikleri ile srekli gncellenir. Bu sayede hedeflenen ęrenme seviyesine ulařılır. Gncelleme yapmak iin nce ıkıřtaki hatalar saptanır, sonra geri yayılım algoritmasından faydalanılarak aęırlıkların deęerleri srekli tespit edilen hatayı azaltacak řekilde yenilenir. Hatayı gncellemede kullanılan geri yayılım algoritmasında aktivasyon fonksiyonları kullanılır. Veriyi ifade etmede bu fonksiyonların rol nemlidir. ok kullanılan aktivasyon fonksiyonları izelge 2.1'de verilmiřtir.

izelge 2.1: Yaygın bilinen aktivasyon fonksiyonları.

Fonksiyon	Matematiksel ifadesi	Grafięi
Sigmoid	$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$	
Tanh	$\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
ReLU	$\text{relu}(x) = \max(x, 0)$	
Leaky Relu	$L_relu(x) = \max(x, 0.1x)$	

2.1.5 Tam baęlı katman

ESA'larda sınıflandırma iřleminin yapıldıęı son katmandır. Kendinden nceki katmanlarda yer alan nronlara direk baęlanarak kendi nronları ile ıktı olarak vektrler elde edilmektedir. Nitelik haritaları evriřim ve havuzlama katmanlarında ok boyutlu

formda işlenirken tam bağlı katmana gelindiğinde boyutları vektörlere indirgenir. Evrişim ve havuzlama katmanlarında ReLU aktivasyon fonksiyonu kullanmak daha elverişli iken, tam bağlı katmanda uygun sınıflandırma yapmak için 0 ile 1 arasında bir olasılık üreten softmax aktivasyon fonksiyonu işlevseldir.

2.1.6 Giriş ve çıkış katmanı

ESA mimarisinin ilk katmanı olan giriş katmanı; görüntüleri temsil eden değerlerin sisteme verildiği kısımdır. Giriş katmanında belirlenen boyuta göre görsellere veya en iyi şekilde temsil eden özniteliklere herhangi bir işlem uygulanmaz. Daha sonraki katmanlarda yer alan evrişim işlemindeki parametre miktarı dolayısı ile başarısı giriş katmanındaki boyut ile doğru orantılıdır. Daha fazla veri ile işlem yapmak daha fazla iş yükü ve maliyet demektir. Birçok ESA modeli giriş için sınıama/yanılma yolu ile en uygun matris değerlerini belirlemişlerdir.

Çıkış katmanı ESA mimarisinde probleme özgü tasarlanıp daha sonra tahmin ve nesne sınıflandırma sonuçlarının sunulduğu katmandır.

2.1.7 Dropout katmanı

Dropout işlemi çok katmanlı bir yapay sinir ağı çok büyük verilerle eğitim yaparken bazen aşırı öğrenme denilen bir ezberleme yoluna gider. Bu istenmeyen durumu engellemek amacı ile ağdaki bazı nöronlar kaldırılır. Seyreltme katmanı olarak da adlandırılan bu işlemde nöronlar arasındaki bağlantı rastgele olarak kesilir. Böylece modelde bulunan nöron geçişlerinin baskın hale gelmesi engellenerek performans artışı sağlanmaktadır.

2.2 ESA Mimarilerinde Kullanılan Blok Yapıları


Literatürde geleneksel derin öğrenme mimarilerinden esinlenerek birçok farklı katman yapısı içeren derin öğrenme mimarileri geliştirilmiştir. Geliştirilen mimarilerde blok yapıları özel olarak tasarlanarak uygulanan probleme özgü ağ davranışı üretilmesi amaçlanmıştır. Bu özel blok yapılarında evrişim işleminin sayısı ve filtre boyutları, havuzlama katmanı yapısı ve aktivasyon fonksiyonu gibi temel parametreler analiz edilmiştir. Geliştirilen mimarilerde aşırı katman fazlalığı ve ele alınan verinin yapısı gibi durumlardan dolayı farklı sorunlar ile karşılaşmıştır. Özellikle kaybolan gradyan problemi çözülmesi gereken önemli problemdir. Bu bölümde gerek bu probleme gerekse en çok kullanılan özel bloklular derin öğrenme mimarilerine kısaca değinilecektir

2.2.1 Kaybolan gradyan problemi

Kaybolan gradyan problemi birden fazla zaman aralığında geri yayılım işleminin sürekli yenilenmesi durumunda ortaya çıkar. Gradyan değeri hem mevcut katmana hem de bir önceki katmana bağlı olarak hesaplandığı için bu problem birden fazla katmanın mevcut değerleri ile ilişkilidir. Geri yayılım algoritmasında kullanılan zincir kuralı ile ilgili ağırlık parametrelerinin güncellenmesi sağlanır. Maliyet fonksiyonunun ilgili ağırlığa göre kısmi türevi hesaplanırken, kullanılan adım genişliği değeri küçük bir değer seçilir. Böylece ağ parametreleri daha küçük bir aralıkta güncellenmiş olur. Çok fazla katman içeren derin öğrenme mimarilerinde bazen kısmi türev sıfıra çok yaklaşır [33]. Bu durumda ağ ağırlıklarının eğitilmesi kısıtlanır. Bu durum kaybolan gradyan problemi olarak adlandırılır. Kısmi türev hesaplamasında maliyet fonksiyonunun ağırlık parametreleri üzerine düzgün dağılımının türev sıfıra çok yaklaşımadan sağlanması arzu edilir. Geliştirilen ESA mimarilerinde bu problemi çözmek için eklemeli bağlantı [35] ve birleştirmeli bağlantı [36] adları verilen yeni ağ modelleri önerilmiştir.

2.2.2 Eklemeli bağlantı: Artık bağlantı modeli

Kaybolan gradyan probleminin çözmek için ağdaki bazı evrişim katmanlarının devre dışı bırakılması hedeflenmiştir. Böylece aşırı soyutlama yapılmasının önüne geçilmesi sağlanmaktadır.



Şekil 2.4: Artık bağlantı modeli.

Yukarıdaki mimaride giriş verisi hem evrişim katmanlarından geçirilmiş hem de evrişim sonucu elde edilen veriler ile toplanarak çıkış verisi elde edilmiştir [35]. Yani aslında giriş verisi herhangi bir işleme tabi tutulmadan doğrudan çıkışa etki ettirilmiştir. Bu bağlantı modeli ile hem ileri yayılım hem de geri yayılım algoritmalarının türevsel hesaplamalarının sıfıra çok yaklaşması engellenmiştir. Bu yapıyı kullanan en popüler mimari ResNet modelidir. Bu modelin parametre sayısına ve katman yapısına göre farklı çeşitleri de geliştirilmiştir.


ResNet mimarisi ESA modellerinin performansını iyileştirmede kullanılan bir mimaridir. Burada temel çıkış noktası ağın yakınsamaya başladığı anlarda kaybolan gradyan probleminin ortaya çıkması ve bu probleme getirilen çözümdür. Özellikle derin ağ mimarisinin derinliği arttıkça doğruluk artmakla birlikte sonraki iterasyonlarda doğruluk değerinin hızlı bir düşüş sergiler. Bu noktada ResNet mimarisi evrişim katmanları arasına kısayollar (artık bağlantılar) ekler. Yapılan deneysel çalışmalarda bu tekniğin bahsedilen problemi çözdüğü gösterilmiştir. ResNet50 modeli ImageNet veri tabanı ile eğitilen ve 50 katmandan oluşan bir derin öğrenme modelidir. Bu modelde 2 tane evrişim katmanı kullanmak yerine 1×1 , 3×3 ve 1×1 şeklinde ardışık evrişim katmanları kullanılır.

ResNet 50 mimarisi aşağıdaki katman elemanlarından oluşur [35]:

- 64 adet 7×7 evrişim kerneli
- Maksimum havuzlama katmanı
- 9 katman: 64 tane 3×3 evrişim kerneli, 1×1 boyutlu 64 kernel, 1×1 boyutlu 256 kernel. Bu üç katman 3 defa ağda tekrar etmektedir.
- 12 katman: 128 tane 1×1 evrişim kerneli, 3×3 boyutlu 128 kernel, 1×1 boyutlu 512 kernel. Bu üç katman 4 defa ağda tekrar etmektedir.
- 18 katman: 256 tane 1×1 çekirdek (cores), 3×3 boyutlu 2 çekirdek, 1×1 boyutlu 1024 çekirdek. Bu üç katman 6 defa ağda tekrar etmektedir.
- 9 katman: 512 tane 1×1 çekirdek, 3×3 boyutlu 512 çekirdek, 1×1 boyutlu 2048 kernel. Bu üç katman 3 defa ağda tekrar etmektedir.
- Ortalama havuzlama katmanı.

2.2.3 Birleştirmeli bağlantı: Dense blok modeli

Kaybolan gradyan probleminin çözümünde yararlanılan bir diğer yöntem ise birleştirmeli bağlantı modelidir. Bu model kullanılarak özellik bilgilerinin daha etkili kullanılması ve türev hesaplamalarının optimale yakın yapılması gerçekleştirilmiştir. Bu modelde her bir katman diğer katmanlara ileri beslemeli yapıda olacak şekilde bağlanmıştır. Uygun transfer fonksiyonu ile de özelliklerin ağına geneline yayılması sağlanmış ve parametre sayısında azalma elde edilmiştir. Dense blok yapısı **Şekil 2.5**'te görülmektedir.



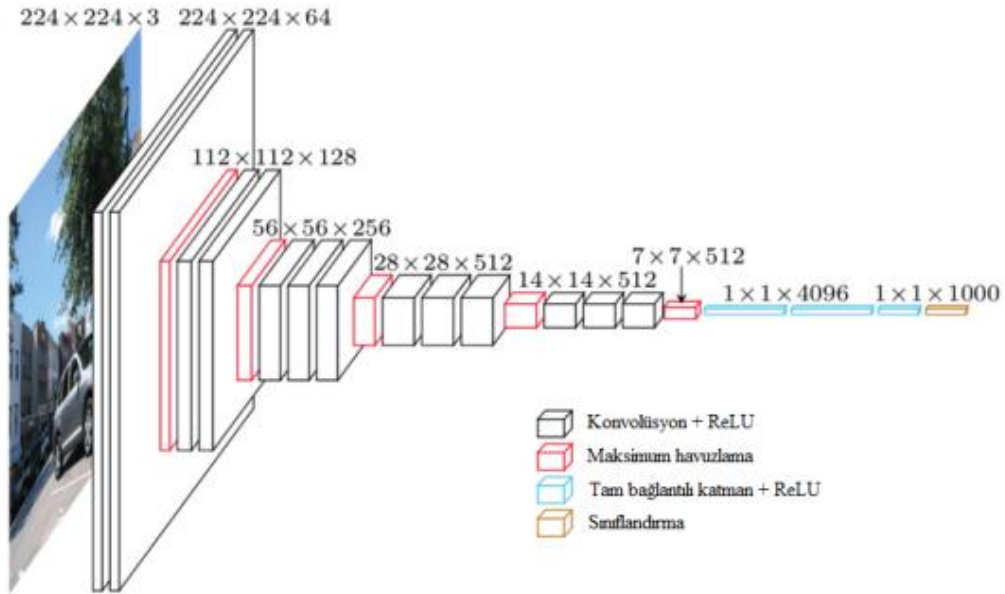
Şekil 2.5: Dense blok yapısı [36].

Birleştirmeli bağlantı modeli kullanan popüler bir derin öğrenme modeli DenseNet mimarisidir. Bu mimarinin farklı modelleri bulunmaktadır. DenseNet121 modeli çok kullanılan ve başarılı sonuçlar üreten bir modeldir. Bu modelde katmanlar arasında yoğun bir bağlantı vardır. Böylece her katmanın bir önceki katmanda üretilen özellik verilerini alması ve kendi ürettiği veriler ile sonraki katmana iletmesi sağlanır. Bu mimaride filtre sayısı az olduğu için parametre sayısı makul seviyededir. Özellik verilerinin boyutları birbirileri ile uyumlu olduğu için birleştirmede herhangi bir problem olmamaktadır. Mimarideki yoğunluk katmanları ana yapı elemanıdır. Bu katmanlar evrişim katmanlarından meydana gelmektedir. Mimarinin son katmanı 1000 birimlik tam bağlı katmana sahip olup 121 tane bağlı evrişim katmanı içermektedir [36]. DenseNet121 mimarisi 4 tane yoğunluk (dense) bloğu ile her iki yoğunluk bloğu arasında bir geçiş katmanı içermektedir. Ayrıca yine normalizasyon, evrişim, ortalama havuzlama katmanı ve ReLU aktivasyon fonksiyonu içermektedir. Sınıflandırıcı olarak softmax sınıflandırıcısı kullanılır.

2.2.4 VGGNet mimarisi

VGGNet mimarisi Simonyan ve Zisserman tarafından geliştirilmiş ve ImageNet veri tabanı üzerinde eğitilmiştir [37]. Bu mimari katman sayısına göre altı farklı mimaride inşa edilmiştir. Evrişim işlemi için 2×2 veya 3×3 boyutunda evrişim filtreleri kullanılmaktadır. Temel olarak 3 tam bağlı katmandan oluşmaktadır. Literatürde farklı versiyonları vardır. Temel VGGNet mimarisi **Şekil 2.6'da** görülmektedir. Şekilden de

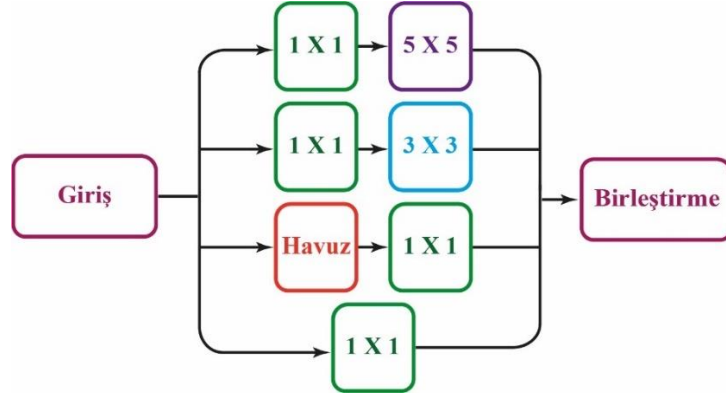
görülebileceği üzere mimari derinleştikçe veri boyutu da azalmaktadır. Böylece ağın performansı daha iyi hale gelmektedir. AlexNet mimarisinde kullanılan yüksek boyutlu kernel yapısı bu mimaride yoktur. VGGNet'te kernel boyutları sabitlenmiştir. VGG16 mimarisinde evrişim ve tam bağlı katman sayısı 16 iken, bu modelin farklı versiyonlarında katman sayıları farklılaşmaktadır. Evrişim işlemindeki adım boyutu katmanlarda 1 veya 2 olarak değişebilmektedir. Havuzlama işlemi çoğunlukla maksimum havuzlama tekniği ile gerçekleştirilir.



Şekil 2.6: VGGNet mimarisinin temel yapısı [38].

2.2.5 Inception mimarisi

Inception (başlangıç) mimarileri Google mühendisleri tarafından geliştirilmiştir [39]. Diğer derin öğrenme modellerinin temel problemlerinden olan hesaplama karmaşıklığına ve büyüklüğüne bir çözüm olarak tasarlanmıştır. Geliştirilen Inception modelinde ağ kurgusu modüllerden oluşmaktadır. Her modülde farklı boyutlarda evrişim ve max-pooling işlemleri uygulanmaktadır. Inception'da her evrişim katmanından önce 1×1 boyutunda evrişim katmanı kullanılmış ve böylece hesaplama maliyeti azaltılmaya çalışılmıştır. Girişlerde uygulanan evrişim işlemi ile giriş verisinin boyutu ilgili bloktan önce azaltılarak ileriki katmanların hesaplama maliyetleri mimarinin ilk aşamalarında azaltılmaya çalışılmıştır. Temel Inception modülüne ait örnek yapı **Şekil 2.7**'de görülmektedir.



Şekil 2.7: Inception modelinin modül yapısı.

3. MATERYAL VE METOT

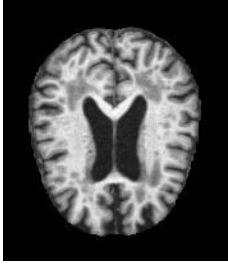
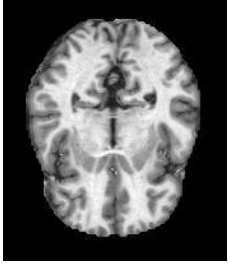
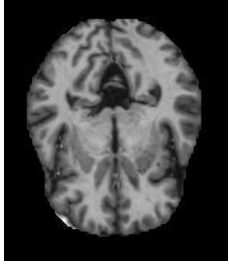
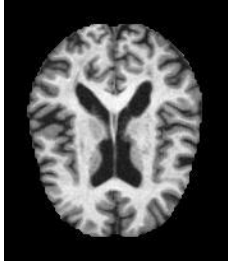
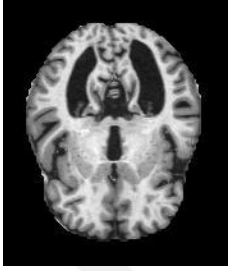
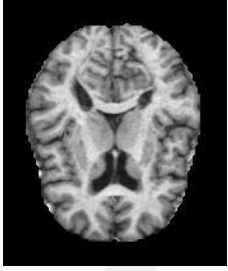
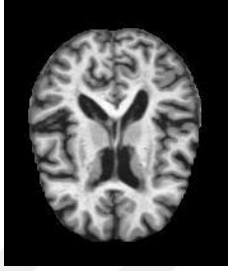
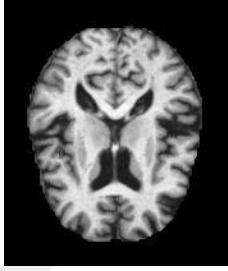
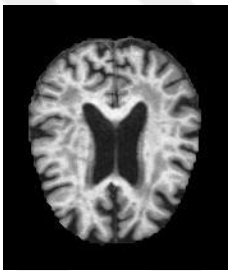
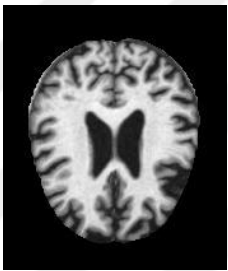
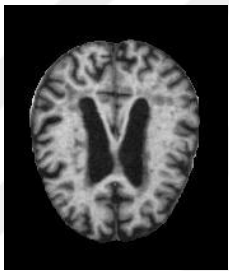
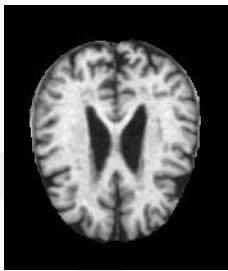

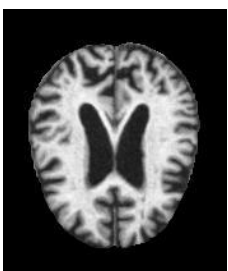
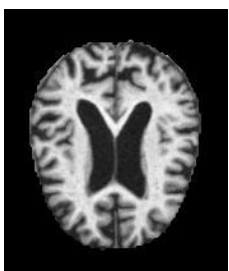
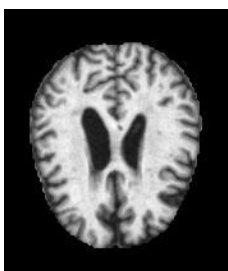
3.1 Alzheimer Veri Kümesi

Bu çalışmada kullanılan veri seti, arařtırmacı Sarvesh Dubey tarafından oluşturulmuřtur [40]. Dubey bu veri setindeki 6400 adet jpeg formatındaki farklı çözünürlükteki MRG verilerini çok sayıda web sitesi, hastane veri tabanları ve erişime açık platformlardan toparlayarak Kaggle veri tabanında paylaşmıştır. Görüntü boyutu 208×176'dır. Veri seti, Alzheimer hastalığının 3 evresi ve hastalık olmayan demanssız olmak üzere 4 sınıftan oluşmaktadır. Bu sınıflar Demansız (NOD), Çok Hafif Demanslı (VMD), Hafif Demanslı (MID) ve Orta Demanslı (MOD) sınıflarıdır. Veri seti için kullanılan MRG verilerinin alındığı hastalar hakkında herhangi bir bilgi verilmediğinden görüntüler hakkında homojen, heterojen ayrımı yapılamamaktadır. Veri tabanındaki Alzheimer hastalık sınıfları ile ilgili bilgiler **Çizelge 3.1**'de verilmiştir.

Çizelge 3.1: Veri setindeki sınıflar ve sınıflarda bulunan örnek sayıları

Sınıf	Veri Sayısı	Yüzde
Demansız (NOD)	3200	50%
Çok Hafif Demanslı (VMD)	2240	35%
Hafif Demanslı (MID)	896	14%
Orta Demanslı (MOD)	64	1%
Veri Seti Toplam	6400	100%

Literatürde yapılan çalışmalarda genel olarak ağın eğitim ve test işlemleri için veri seti %80 eğitim ve %20 test olacak şekilde 2'ye bölünmektedir [13], [23]. Alzheimer hastalığının farklı evrelerine ve sağlıklı bireylere ait bazı örnek görüntüler **Şekil 3.1**'de görülmektedir.

Demansız				
Çok Hafif Demanslı				
Hafif Demanslı				
Orta Demanslı				

Şekil 3.1: Alzheimer Veri Kümesi Sınıfları Örnekleri

Çizelge 3.1’ de detayları verilen Alzheimer veri seti literatürde yoğun bir şekilde kullanılmaktadır. Derin öğrenme yöntemleri ile destek vektör makineleri gibi geleneksel yöntemler de kullanılarak hastalığın evreleri sınıflandırılmaya çalışılmıştır. Ayrıca veri setinin genelliğini ve geçerliğini iyileştirmek için veri artırma ve gürültü giderme gibi bazı ön işlem adımları da uygulanmıştır. Veri tabanını kullanarak Alzheimer sınıflandırması yapan bazı güncel literatür çalışmaları Çizelge 3.2’ de verilmiştir.

Çizelge 3.2: Tezde kullanılan Alzheimer veri setini kullanarak yapılmış olan literatür çalışmaları

Referanslar	Yöntemler	F1-skoru (%)	Doğruluk (%)
Sharma ve diğ. [25]	Transfer öğrenme, DVM ve permütasyon tabanlı makine öğrenimi	90,25	91,75
Sharma ve diğ. [15]	Transfer öğrenme temelli Inception modeli	94,75	94,92
Zena ve diğ. [10]	Modifiye edilmiş VGG16 Modeli	98	97,625
Singh ve diğ. [13]	Önerilen CNN+Softmax Modeli	97	98,59
Toğaçar ve diğ.[23]	Geliştirilmiş VGG16 Modeli Denetimli ve denetimsiz karşıt	–	99,94
Shu ve diğ. [16]	(contrastive) öğrenme	73	92
liu ve diğ. [24]	ResNet+Dikkat mekanizmaları	95	96,25

3.2 Geliştirilen Özel Blok Yapılı Derin Öğrenme Modelleri

Literatürde mevcut olan ESA mimarilerinin bir kısmı tamamen yeni bir mimari tasarımı yaparak ortaya çıkarken, veri işlemede kullanılan çoğu ESA modeli ise mevcut mimarilerinin geliştirilmesi ve iyileştirilmesine dayalı olarak kullanılmaktadır. Herhangi bir modeldeki evrişim katman yapısı, bağlantı şekli ve katmanların diziliş sırası en çok dikkat edilen hususlar arasındadır. Veri boyutunu indiren, işlem yükünü azaltan bir mimari yapıdaki katman modeli bir diğer mimariye entegre edilerek o mimarinin güçlenmesine ve zayıf yönlerinin azaltılmasına olanak sağlamaktadır. Ayrıca ReLU aktivasyon fonksiyonlarının seçimi de mimarilerin performansına katkıları sunmuştur [34]. Özellikle Inception ve ResNET mimarilerinin üstün yönleri kullanılarak oldukça güçlü mimariler geliştirilmiştir [41].

Tezin bu bölümünde önceki bölümlerde kuramsal temelleri verilen geleneksel evrişim modeli, ResNET50 mimarisindeki bağlantı modeli ve Inception V3 blok yapısı kullanılarak farklı derin öğrenme mimarileri tasarlanmıştır. Böylece mimarilerin önemli yetenekleri diğer bir model ile birlikte kullanılarak modellerin güçlü yönleri birbirine tamamlayıcı olarak kullanılmıştır. Geliştirilen modellerin ResNET bloklarında iki evrişim ve bir atlama bağlantısı vardır. Evrişim kerneli boyutu 3×3 'tür. Geleneksel evrişim kullanan özel bloklarda iki evrişim filtresi kullanılmış olup boyutları 3×3 'tür. Inception modelinde ise Şekil 2.7'de verilen blok bağlantı modeli kullanılmıştır. Inception bloğunda altı evrişim, bir havuzlama ve bir tane de filtre birleştirme vardır. Havuzlama katmanlarında adım sayısı 2 olarak alınmıştır. Özel blok yapıları arasında maksimum havuzlama kullanılırken, softmax sınıflandırıcı öncesinde ise ortalama havuzlama katmanı

ve tam bağı katman kullanılmıştır. Özellikle geleneksel evrişim modeli yerine ResNET50 ve InceptionV3 modelindeki evrişim ve özel blok yapılarının Alzheimer hastalığı tespitindeki etkinliklerinin belirli bir veri tabanı üzerinde test edilmiştir. Geliştirilen beş farklı mimariye ait blok diyagram **Şekil 3.2**'de görülmektedir. Geliştirilen mimarilerde **Şekil 3.2**'deki sadece özel blok yapısı olarak adlandırılan dört kısımda farklı mimarilerin özel blok yapıları kullanılmıştır. Diğer blok yapılarında değişiklik yoktur. Bu aşamada geliştirilen beş farklı hibrit derin öğrenme modeli alt başlıklar halinde kısaca açıklanacaktır.

3.2.1 Model 1: Inception-ResNet

Bu modelde giriş görüntüsü geleneksel evrişim katmanından geçirildikten sonra dört özel blok yapısı InceptionV3 ve ResNet50 mimarilerindeki özel blok yapılarından oluşmaktadır. **Şekil 3.2**'de verilen mimaride özel blok yapısı-1 ve özel blok yapısı-2 Inception bağlantı modeli içermektedir. Bu iki yapıdan geçirilen Alzheimer verisi maksimum havuzlama işlemi sonrasında ResNet50 bağlantı modeli içeren özel blok yapısı-3 ve özel blok yapısı-4'ten geçirilmiştir. Ortalama havuzlama işlemi sonrasında softmax sınıflandırıcı ile veriler sınıflandırılmıştır. Geliştirilen bu model ile Alzheimer MRG verisindeki ayırt edici bölgelerin özelliklerinin yakalanması ve ağı eğitiminde gradyan yok olması probleminin engellenmesi sağlanmıştır. ResNet50 mimarisindeki artık blok yapısı ile bir veya daha fazla katmanın göz ardı edilmesi ve artık değerlerin ileriki katmanlara iletilmesi sağlanmıştır. Böylece ağıdaki aşırı soyutlama da azaltılmıştır. Yapılan deneysel çalışmalarda geliştirilen bu modelin InceptionV3 modeli ile uyumlu çalıştığı ve etkin sonuçlar ürettiği görülmüştür.

Tez çalışmaları kapsamında geliştirilen beş modelin özel blok yapılarında kullandığı mimariler **Çizelge 3.3**'te verilmiştir.

Çizelge 3.3: Geliştirilen beş farklı derin öğrenme modelindeki özel blok yapılarının kullandıkları mimariler

Model	Özel Blok 1	Özel Blok 2	Özel Blok 3	Özel Blok 4
Model 1	Inception Bloğu	Inception Bloğu	ResNet Bloğu	ResNet Bloğu
Model 2	Evrişim Bloğu	Evrişim Bloğu	Inception Bloğu	Inception Bloğu
Model 3	ResNet Bloğu	ResNet Bloğu	Evrişim Bloğu	Evrişim Bloğu
Model 4	Inception Bloğu	Inception Bloğu	Inception Bloğu	Inception Bloğu
Model 5	ResNet Bloğu	ResNet Bloğu	Inception Bloğu	Inception Bloğu

3.2.2 Model 2: Geleneksel evriřim -Inception

Bu modelde **řekil 3.2'** de grlen zel blok yapısı-1 ve zel blok yapısı-2 geleneksel evriřim iřlemi ieren katman yapısı iermektedir. Geleneksel evriřim bloklarının her birinde iki evriřim katmanı kullanılmıř olup filtre boyutları 3x3'tr. zel blok yapısı-3 ve zel blok yapısı-4'te ise ardıřık Inception blok yapıları bulunmakta olup bloklar arasında maksimum havuzlama adımı vardır. Her bir Inception modlnde farklı boyutlarda evriřim ve havuzlama katmanları vardır. Ancak evriřim iřlemi Inception mimarisine uygun olacak řekilde evriřim/havuzlama baėlantıları ve filtre birleřtirme adımları mevcuttur.

3.2.3 Model 3: ResNet-Geleneksel evriřim

Model 3'te zel blok yapısı-1 ve zel blok yapısı-2'de ResNet50 baėlantı blokları varken, zel blok yapısı-3 ve zel blok yapısı-4'te ise geleneksel evriřim iřlemi ieren katmanlar kullanılmıřtır. Burada ama ResNet50 ile geleneksel derin ėrenme modelindeki evriřime dayalı zellik ıkarma ile veriyi soyutlama iřlemlerinin birbirlerine olan etkilerini incelemektir. Yrtlen alıřmalarda ResNet50'nin avantajlarından olan artık baėlantı ve hesaplama yknn azaltılması ile zellik ıkarmada etkinlik saėlanmıřtır. Bu baėlantı mimarisi ile aėın gradyan kaybolması problemi ile karřılařmadıėı grlmřtr.

ResNet' teki atlama baėlantı yapısı sayesinde eėitim iřlemi birkaç katman atlanarak yapılır. Bylece aė katmanlarının MRG verisinde zellik haritalama iřlemini ėrenmesinden ziyade, aėın artık haritalama yapmasına imkan sunmaktır. Atlama katmanı kullanılarak katmanların tm mimariye olan etkileri de gzlemlenerek ėrenme iřlemine negatif etkide bulunan katmanların tespit edilmesi ve nlenmesi saėlanmıřtır. Geleneksel evriřim iřlemi ile de bu ResNet alıřma metodolojisinin birlikte ve uyumlu bir řekilde alıřabildiėi anlařılmıřtır.

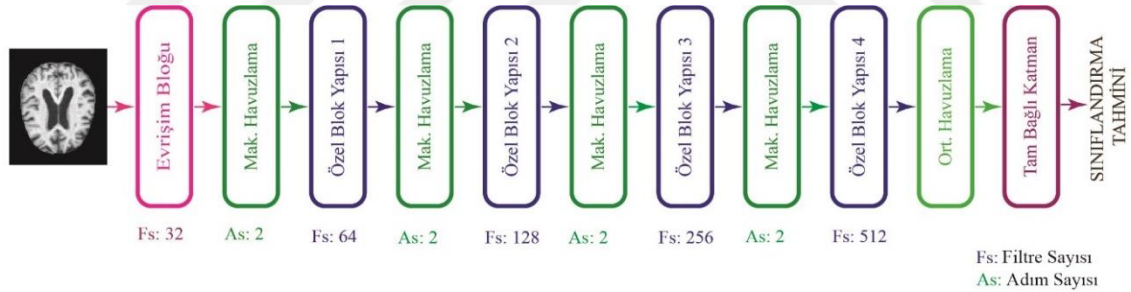
3.2.4 Model 4: Inception-Inception

nerilen bu model sadece Inception modllerinden oluřan byk boyutlu GoogLeNet mimarisinin kk boyutlu ve katman yapısı kısmen deėiřtirilmıř haline benzemektedir. GoogLeNet' ten farklı olarak bařlangıta 32 adet filtre kullanan bir tane evriřim katmanı bulunmaktadır. Ayrıca havuzlama katmanlarında ve bloklardaki filtre sayılarında farklılıklar vardır. nerilen mimarinin drt zel bloėunda sırasıyla 64, 128, 256 ve 512 filtre kullanılmıřtır. Bylece Alzheimer verilerini sınıflandırmaya zg olarak

tasarlanan InceptionV3 modelinin etkinliđi ölçülebilmıştır. Geleneksel evriřim katmanı ve ResNet50 blok yapısı kullanılmaksızın sınıflandırmada makul kabul edilebilecek sonuçlara ulařılabileceđi anlařılmıřtır.

3.2.5 Model 5: ResNet-Inception

Bu alıřmada model 1’de önerilen blok sıralamasının yerleri deđiřtirilerek ađın eđitim iřleminde ResNet50 ve InceptionV3 modellerinin etkilerinin gözlemlenmesi amalanmıřtır. Burada Inception bađlantı blok yapısının ađın ilk katmanlarında kullanılmasının daha iyi sonuçlar ürettiđi görülmüřtür. ünkü Inception blođundaki evriřim iřlem yapısı ve bađlantı řekli dahili havuzlama ile birlikte kullanılarak ađın özellik ıkarma performansına olumlu etki yapmıřtır. ResNet’teki artık bađlantı mantıđı Inception modelinden önce kullanıldıđında beklenen gradyan kaybolması ve ađın ezberlemesi gibi problemleri tam olarak özememiřtir. Model 1’de ise Inception modelinden elde edilen soyut özellikler ResNet ile tekrar ele alınarak aşırı soyutlama ve özellik kaybı gibi problemlere karřı ađın kararlılıđı güçlendirilmiřtir. Son olarak geleneksel evriřim modeli ile ResNet bađlantı blok modelinin daha iyi alıřtıkları ve daha yüksek sonuçlar ürettiđi görülmüřtür.



řekil 3.2: Tez alıřmasında geliştirilen özel blok yapılı derin öđrenme modeli

4. UYGULAMA VE DEĞERLENDİRME

Tezin bu bölümünde Alzheimer hastalığını tespit etmek için önerilen beş farklı derin öğrenme modelinin sık kullanılan bir Alzheimer veri seti [40] üzerinde performansları analiz edilip yorumlanmıştır. Modellerin birbirleri ile ve güncel derin öğrenme mimarileri ile karşılaştırmaları yapılmıştır. Karşılaştırmalarda ResNet50, Resnet101, VGG16, VGG19, InceptionV3 ve MobileNet derin öğrenme mimarileri kullanılmıştır. İlk olarak karşılaştırmalarda kullanılan metrikler ile ilgili temel bilgilere yer verilecektir.

4.1 Değerlendirme Metrikleri

Önerilen modellerin sınıflandırma performanslarının nicelik olarak objektif şekilde değerlendirilmesi için farklı metrikler kullanılmaktadır. En çok kullanılan metrikler doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1-skor'dur. Bahsedilen sayısal metrikler **Şekil 4.1**'de verilen karmaşıklık matrisinde bulunan TP, TN, FP ve FN değerleri ile hesaplanmaktadır. TP, TN, FP ve FN parametreleri ile ilgili açıklamalar şu şekildedir:

- TP (True Positive-Gerçek Pozitif): Gerçekte pozitif olan bir değer yine pozitif olarak tahmin edilmesidir.
- TN (True Negative-Gerçek Negatif): Gerçekte negatif olan bir değer yine negatif olarak tahmin edilmesidir.
- FP (False Positive-Yanlış Pozitif): Gerçekte negatif olan değer yanlış olarak pozitif tahmin edilmesidir.
- FN (False Negative-Yanlış Negatif): Gerçekte pozitif olan değer yanlış olarak negatif tahmin edilmesidir.

		Tahmin Edilen Metrik	
		Positive	Negative
Gerçek Değeri	Positive	TP (True Positive)	FN (False Negative)
	Negative	FP (False Positive)	TN (True Negative)

Şekil 4.1: Karmaşıklık matrisi.

•Doğruluk (Accuracy): Yapılan tahminin doğruluk yüzdesini ifade etmek için kullanılır. Doğru olarak tahmin edilen değerlerin tüm tahmin değerlerin toplamına oranıdır.

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.1)$$

•Hassasiyet (Precision): Yapılan pozitif tahminlerin gerçekte ne kadarının pozitif olduğunu ifade etmeye yarar. **Denklem 4.2'** de gösterildiği gibi TP gerçek pozitif tahminlerin bütün pozitif tahminlerin oranlanmasıdır

$$\text{Hassasiyet (Precision)} = \frac{TP}{TP + FP} \quad (4.2)$$

•Duyarlılık (Recall): Yapılan tahmin işlemlerinin gerçek pozitif değerlerin kaçının doğru olarak sonuçlandığı bilgisini verir. **Denklem 4.3'** te gösterildiği gibidir.

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FN} \quad (4.3)$$

•F1 Skoru: Hassasiyet (precision) ve Duyarlılık (recall) değerlerinin harmonik ortalamasıdır. **Denklem 4.4'** te verilmektedir.

$$F1 \text{ Skoru} = \frac{2x (\text{Hassasiyet} \times \text{Duyarlılık})}{(\text{Hassasiyet} + \text{Duyarlılık})} \quad (4.4)$$

4.2 Geliştirilen Modellerin Sınıflandırma Sonuçları

Tez çalışmasında geliştirilen beş farklı derin öğrenme model mimarisi bölüm 3.1'de detayları verilen Alzheimer veri seti üzerinde test edilmiştir. Veri tabanındaki görüntüler %80 eğitim, %10 geçerlilik (validation) ve %10 test olmak üzere üç farklı gruba ayrılmıştır. Görüntüler rastgele ve kümeler arasında kesişim olmayacak şekilde tamamen bağımsız olarak oluşturulmuştur. Eğitim için 50 epoch değeri ve batchsize 16 olarak belirlenmiştir. **Çizelge 4.1'**de modellere ait sınıflandırma sonuçları verilmiştir. Görüleceği üzere tüm performans metriklerinde Model 1 en iyi sonucu üretmiştir Model 5 ise en düşük sonuçlara sahiptir. Model 1'de InceptionV3 ve ResNet50 mimarisi **Şekil 3.2'**de detayları verilen özel blok yapılarında kullanılmıştır. Geliştirilen beş modeldeki Inception

bloklarında bir adet 5×5, bir adet 3×3, 4 tane de 1×1 boyutunda evrişim filtresi vardır. Bu filtrelerden 64'er adet kullanılmıştır. Model 1 ile Model 5 arasındaki en önemli fark özel blok yapısında InceptionV3 ve ResNet50 bloklarının sıralamasıdır. Yapılan deneysel çalışmalar Alzheimer MRG verilerinin ilk olarak Inception bloklarından geçirilmesinin daha iyi özellik çıkarımı sağlamakla beraber ağın eğitim kararlılığına olumlu katkılar sunduğunu göstermiştir. Çünkü Model 5'te ilk olarak MRG verisi iki adet ResNet bloğundan geçtikten sonra Inception bloklarına ulaşmaktadır. Bu durumun kısmen de olsa kaybolan gradyan problemine ve aşırı soyutlamaya neden olduğu görülmüştür. Bu durum sınıflandırma sonuçlarına da olumsuz yansımıştır. Bu tespitler sayesinde özellikle Inception ve ResNet blok yapılarının birlikte ve sadece blok yapı bağlantı mimarileriyle birlikte çalışma karakteristikleri ortaya çıkarılmıştır.

Çizelge 4.1: Önerilen beş modelin sınıflandırma sonuçlarına ait metrikler

Model	Doğruluk (Accuracy)	Hassasiyet (Precision)	Duyarlılık (Recall)	F1-Skoru
Model 1	95,78	95,93	95,78	95,76
Model 2	95	95,06	95	95
Model 3	94,84	95,01	94,84	94,77
Model 4	93,75	94,06	93,75	93,68
Model 5	93,75	94,03	93,75	93,8

Model 2'de geleneksel evrişim blokları ile Inception bloklarının etkileşimleri incelenmiştir. Özel blok-1'de 3×3 boyutunda 64 adet geleneksel evrişim işlemi uygulanırken, özel blok-2'de ise 3×3 boyutunda 128 adet geleneksel evrişim işlemi uygulanmıştır. Özel blok-3 ve özel blok-4 Inception blok yapılarıdır. Özel blok-3'te bir adet 5×5, bir adet 3×3, 4 tane de 1×1 boyutunda evrişim filtresi vardır. Inception blok çıkışında filtre birleştirme yapılarak 1×256 boyutunda özellik vektörü elde edilmiştir. Özel blok-4 ise özel blok-3 ile aynıdır. **Çizelge 4.1'**den de görüleceği üzere bu model ile diğer 3 modele (Model 3, Model 4 ve Model 5) göre daha iyi sınıflandırma sonuçlarına ulaşılmıştır. Özellikle Model 3'teki Resnet ve geleneksel evrişimin birlikte kullanıldığı yapıya göre daha etkin sonuçlar elde edilmiştir. Elde edilen bu sonuç iki hususu öne çıkarmaktadır. Tasarlanacak ağlarda eğer geleneksel evrişim ile Resnet/Inception mimarileri birlikte ve ardışık blok yapısında kullanılacaksa, ilk katmanlarda önceliğin geleneksel evrişim katmanlarına verilmesinin uygun olacağı gözlemlenmiştir. Özellikle Alzheimer MRG verisi sınıflandırma uygulamaları için ağın eğitim işleminde ve optimal kayıp değerine ulaşmada daha iyi sonuçlara ulaşılabilecektir. Vurgulanması gereken bir

diğer önemli husus ise model 1 ve 2'nin her ikisi de Alzheimer hastalığının evrelerini gösteren veri setindeki 4 sınıfı da kendi aralarında hassas şekilde ayırt edebildikleridir. Bu durum daha sonra verilecek olan ROC (Receiver Operating Characteristic) eğrilerinde de gösterilmiştir.

Model 3'ün geliştirilmesinde temel motivasyon ResNet ve geleneksel evrişim işlemlerinin Alzheimer hastalığının MRI verileri kullanılarak sınıflandırılmasında birlikte kullanılmalarının etkilerini incelemektir. Bu çerçevede oluşturulan modelde özel blok-1 ve özel blok-2'de ResNet blokları kullanılmıştır. Özel blok-3 ve özel blok-4'te ise geleneksel evrişim işlemi kullanılmıştır. Özel blok-1'de ResNet bloğunda 3×3 boyutunda 64 adet evrişim filtresi, Özel blok-2'deki ResNet'te ise 128 adet 3×3 evrişim filtresi kullanılmıştır. Özel blok-3 ve Özel blok-4 ise sırasıyla 256 ve 512 adet 3×3 boyutunda geleneksel evrişim işlemi uygulanmıştır. Bu modelde Model 1 ve 2'ye göre kısmen daha başarısız sonuçlar elde edilmiştir. Ancak bu modelin sınıflandırma doğruluğu, hassasiyet ve duyarlılık metrikleri özellikle Model 2'ye çok yakındır (**Çizelge 4.1**). Bu noktada geleneksel evrişim katman yapısının hem Inception hem de ResNet mimarileri ile Alzheimer verisi özelinde benzer çalışma davranışlarına sahip olduğu söylenebilir. Fakat Model 2'de hem geleneksel evrişimin ağır ilk başlangıç katmanlarında kullanılması hem de Inception modeliyle birlikte bir mimaride kullanılması az da olsa başarıya etki etmiştir. Özellikle Inception modelindeki blok yapısı ile geleneksel evrişimden alınan büyük boyutlu giriş vektöründe ayırt edici özelliklerin ağ içerisinde aşırı soyutlamaya daha az uğradığı söylenebilir. Ayrıca Model 3'te de diğer modellerde olduğu gibi Alzheimer hastalığının farklı evrelerini gösteren farklı sınıf verileri de diğer sınıflardan başarılı şekilde ayırt edilebilmiştir. Bu gerçeklik tezin ileriki bölümlerinde verilen ROC eğrilerinde de görülmektedir.

Model 4'te ise 4 özel blok yapısının hepsinde sadece Inception blokları kullanılmıştır. Böylece hem ResNet'in hem de geleneksel evrişim katmanlarının Inception blok yapısına olan olumlu/olumsuz etkileri daha yalın bir şekilde izlenmiştir. **Çizelge 4.1**'de görüldüğü gibi, önerilen blok yapısı modeli ile Alzheimer MRG verilerinin sınıflandırılmasında InceptionV3 modeli diğer üç modele göre daha düşük sonuçlar vermiştir. Bu durumda geleneksel evrişim katmanlarını veya ResNet blok yapılarının Inception modeliyle birlikte kullanılmasının daha iyi sonuçlar vereceği gözlemlenmiştir.

Model 5'te ise ağın ilk iki başlangıç bloğunda ResNet blokları kullanılmıştır. Bu blokları ise Özel blok-3 ve özel blok-4'te Inception blokları izlemektedir. Bu model Model 1'in tersi şeklinde bağlantı sıralamasına sahiptir. Model 1 en yüksek sonuçlara ulaşırken,

model 5 ise modeller arasında en düşük sonuçlara sahiptir (**Çizelge 4.1**). Bu noktada iki model arasındaki temel fark ResNet ile Inception modellerin bağlantı sırasıdır. Dolayısıyla Alzheimer MRG verilerini sınıflandırmada özel blok yapılarında önceliğin yani ağın ilk giriş katmanlarının Inception bağlantı modeline ayrılması gerektiği sonucuna ulaşılmıştır. Ayrıca genel olarak geleneksel evrişim katmanlarının hem Inception hem de ResNet blok yapıları ile uyumlu çalıştığı görülmüştür.

4.3 Geliştirilen Modelin Diğer Derin Öğrenme Modelleri ile Karşılaştırılması

Bu bölümde tez çalışmalarında geliştirilen beş farklı derin öğrenme mimarisi literatürdeki ResNet50 [35], ResNet101 [42], InceptionV3 [39], VGG16 [37], VGG19 [37] ve MobileNet [43] derin öğrenme mimarileri ile karşılaştırılmıştır. Karşılaştırma metrikleri olarak sınıflandırma doğruluğu, hassasiyet, duyarlılık ve F1-skor kullanılmıştır. Ayrıca tüm yöntemlere ait ROC eğri analizi yapılmıştır.


Çizelge 4.2'de yöntemlerin karşılaştırma sonuçları verilmiştir. Görüleceği üzere geliştirilen Model 1, Model 2 ve Model 3 en iyi sınıflandırma sonuçlarını elde etmiştir. Geliştirilen Model 4 ve Model 5 ise sıralamada 11 yöntem arasında altıncı ve yedinci sıradadır. Özellikle özel blok yapı mimarisine dayanan ve farklı derin öğrenme mimarilerinin üstün yönlerini kullanmaya dayanan Model 1, Model 2 ve Model 3 mimarileri oldukça başarılı sonuçlar üretmişlerdir. Aslında geliştirilen beş model karşılaştırmada da kullanılan Resnet50 ve InceptionV3 mimarilerinin sadece belirli blok yapısını kullanmaktadır. Ancak karşılaştırmada kullanılan orijinal Resnet50 mimarisi [35] kendi içerisinde 50 katmanlı bir yapıya sahiptir. ResNet50 mimarisinin katman yapısı bölüm 2.2.2'de verilmiştir. Yine tezde geliştirilen modellerde yine InceptionV3 mimarisinin sadece özel blok yapısı kullanılmış olup çok katmanlı bilinen InceptionV3 mimarisi [39] karşılaştırmada kullanılmıştır. Geliştirilen ilk üç model orijinal ResNet50 ve InceptionV3 modellerine göre daha iyi sonuçlar üretmiştir. Ayrıca geliştirilen modeller ResNet50 ve InceptionV3 mimarilerine göre daha az ağ derinliğine ve katman sayısına sahiptir. Bu nedenle geliştirilen modellerin işlem hızı daha iyi bir noktadadır. Elde edilen sonuçlar incelendiğinde, orijinal ResNet50 ve InceptionV3 modellerini sahip oldukları artık bağlantı ve birleştirmeli başlangıç yapılarını art arda şekilde çok katmanlı şekilde kullanmak yerine, bu mimarilerin temel özel blok yapılarını çok daha az sayıda ve hibrid şekilde kullanmanın istene sonuçları verebileceği görülmüştür.

Önerilen beş model VGG16, VGG19, ResNet101 ve MobileNet mimarilerinden de daha iyi sonuçlar üretmiştir. Aslında karşılaştırmalarda kullanılan bu dört model birçok problemde çok iyi sonuçlar vermektedir. Ancak Alzheimer hastalık tespiti için tasarlanan özel blok yapılı mimari sahip olduğu avantajlar ile bu mimarileri geride bırakmıştır. Önerilen modeller özellikle hem ResNet'in hem de InceptionV3'ün blok yapılarını birlikte kullanarak bu iki modelin esas anlamdaki temel yeteneklerinden istifade etmişlerdir. Yine geleneksel evrişim katmanlarını da kullanarak karmaşık model tasarımına olan ihtiyacında giderilebileceği anlaşılmıştır.

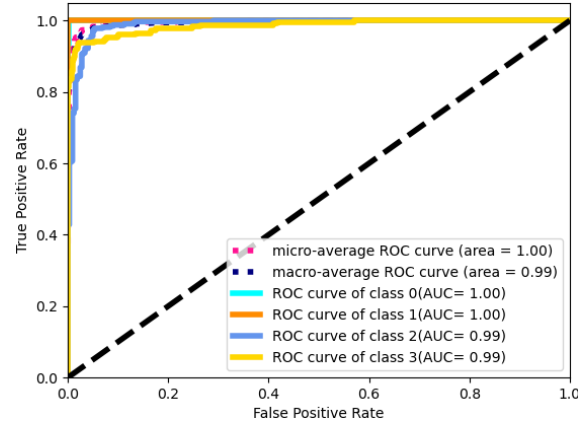
Çizelge 4.2: Önerilen modeller ile güncel modellerinin sınıflandırma sonuçları

Model	Doğruluk (accuracy)	Hassasiyet (precision)	Duyarlılık (recall)	F1-Skoru
Model 1	95,78	95,93	95,78	95,76
Model 2	95	95,06	95	95
Model 3	94,84	95,01	94,84	94,77
ResNet50	94,69	94,93	94,69	94,61
InceptionV3	94,06	94,13	94,06	94,08
Model 4	93,75	94,06	93,75	93,68
Model 5	93,75	94,03	93,75	93,8
ResNet101	93,12	93,26	93,12	93,09
VGG16	89,84	89,88	89,84	89,86
MobileNet	77,5	78,38	77,5	76,87
VGG19	50	25	50	33,33


Yöntemlere ait ROC eğrileri **Şekil 4.2'**de verilmiştir. Sonuçlardan da görüleceği üzere önerilen ilk üç model en iyi sonuçlara ulaşmıştır. Alzheimer hastalık evrelerini birbirinden ve sağlıklı MRG verilerinden başarılı şekilde ayırt edilmiştir. Model 4 ve model 5 ise kabul edilebilir sonuçlara sahiplerdir. Ayrıca ROC eğrilerinde de önerilen tüm modellerin VGG16, VGG19, ResNet101 ve MobileNet mimarilerinden daha iyi ROC sonuçlarına ulaştığı vurgulanmalıdır. Böylece MRG verilerindeki sınıflar arası benzerliğe rağmen, önerilen yöntemler ayırt edici özellikleri elde ederek Softmax sınıflandırıcının yeteneğini arttırmışlardır.




Model 1




Model 2




Model 3




ResNet50




Inception V3




Model 4




Model 5



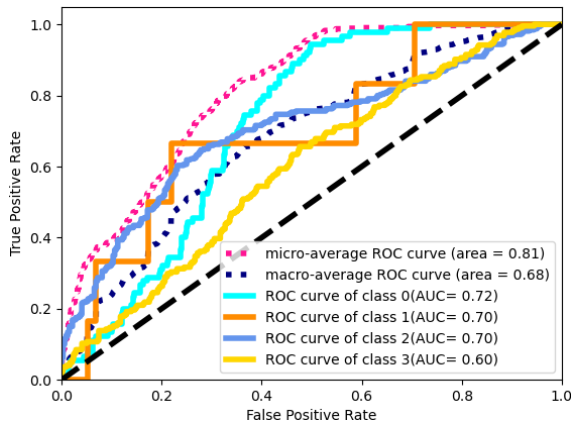
ResNet101



VGG16



MobilNet



VGG19

Şekil 4.2: Geliştirilen modellere ve karşılaştırmada kullanılan yöntemlere ait ROC eğri grafikleri.

5. SONUÇLAR VE ÖNERİLER

Bilgisayar destekli tanı ve teşhis sistemleri hastalık tespitinde hızlı ve güvenilir sonuçlara ulaşmada önemli katkıları sunmaktadır. Özellikle karar verme süresini azaltmakla beraber güvenilir matematiksel sonuçlar ile de medikal uzmanlar için kolaylaştırıcı bilgi ve bulgular ortaya koyabilmektedir. Alzheimer hastalığı özelinde özellikle bu hastalığın farklı evrelerinin hassas şekilde tespit edilebilmesi tedavi protokolünün düzenlenmesinde önemli bir etkiye sahiptir. Bu noktada makine öğrenmesi ve görüntü işleme yöntemleri Alzheimer hastalık tespitinde kullanılmaktadır.

Bu tez çalışmasında Alzheimer hastalığının farklı evrelerini tespit edebilen derin öğrenme tabanlı 5 farklı model geliştirilmiştir. Literatürdeki birçok çalışmada da kullanılan güncel bir Alzheimer MRG veri seti kullanılmıştır. Bu veri tabanında Alzheimer hastalığının en sık karşılaşılan üç evresi bulunmaktadır. Bu evreler Çok Hafif Demanslı, Hafif Demanslı ve Orta Demanslı şeklinde tanımlanmaktadır. Ayrıca veri tabanında sağlıklı bireylere ait MRG verileri de vardır. Yürütülen çalışmalarda derin öğrenme modellerinin özel blok yapıları hibrit şekilde kullanılarak Alzheimer hastalık tespitine yönelik beş farklı derin öğrenme mimarisi geliştirilmiştir. Özel blok yapıları olarak geleneksel evrişim modeli, Inception blok yapısı ve ResNet blok yapısı kullanılmıştır. Özellikle Inception ve ResNet mimarilerinin içerdikleri özel blok yapılarının birlikte kullanımları ile hastalık tespitindeki performansları incelenmiştir. Geliştirilen beş farklı modelin her birinde dört adet özel blok yapısı bulunmaktadır. Bu blok yapılarında evrişim modeli, Inception blok yapısı ve ResNet blok yapıları farklı sıralarda kullanılmıştır. Böylece ağırlık veriyi aşırı soyutlaması ve kaybolan gradyan problemi gibi olumsuz durumlara karşı performansı incelenmiştir. Ayrıca bu modeller ile farklı özel blok yapılarının birlikte çalışma davranışlarını da inceleme imkanı elde edilmiştir. Özellikle ResNet mimarisindeki artık bağlantı modeli ile Inception mimarisindeki evrişim işlemi mantığının aynı derin öğrenme modelinde uyumlu çalışmaları gözlemlenmiştir. Önerilen mimarilerdeki özel blok yapılarının sıralamasının sonuçlar üzerinde etkili olduğu anlaşılmıştır. Yine Inception mimarisindeki özel blok yapısının bulunduğu Model 1 ve Model 2'de en yüksek sonuçlara ulaşılmıştır. Böylece Inception mimarisinin hem geleneksel evrişim modeli ile hem de ResNet özel blok yapısı ile Alzheimer tespitinde uyumlu çalıştığı anlaşılmıştır.

Yapılan çalışmalara ilişkin elde edilen sonuçlarda önerilen beş modelden üç tanesinin (Model 1, Model 2 ve Model 3) literatürdeki güncel derin öğrenme

modellerinden daha iyi sonuçlar elde ettikleri görülmüştür. Model 4 ve Model 5 ise yine de VGG16, ResNet101, MobilNet ve VGG19 gibi güçlü modellerden daha iyi sonuçlara ulaşmıştır. Değerlendirme metrikleri olarak doğruluk, F1-skor, hassasiyet ve duyarlılık ölçütleri kullanılmıştır. Tüm ölçütlerde özellikle ilk üç model en yüksek başarıya sahiptir. Bu sonuç bağlamında, Alzheimer hastalığının iki boyutlu MRG verileri kullanılarak etkin şekilde tespit edilebileceği sonucuna varılmıştır. Ayrıca farklı derin öğrenme modellerinin sadece sahip oldukları özel blok yapılarını kullanarak ele alınan probleme özel olarak hibrit derin öğrenme mimarileri geliştirilebileceği uygulamalı olarak görülmüştür. Bu şekilde bir mimari tasarımının yöntemlerin başarısını iyileştirdiği gözlemlenmiştir.

Elde edilen sonuçlar umut verici olmakla beraber, gelecekte daha büyük boyutlu veri setleri üzerinde de uygulamalar yapılabilir. Yine mevcut derin öğrenme mimarilerindeki diğer farklı özel blok yapıları da incelenerek Alzheimer hastalık tespitindeki performansları incelenebilir. Modellerin eğitim ve test performanslarını iyileştirmek amacıyla hiper parametre ayarlamaları ile Fine-tuning işlemlerinde güncellemelere gidilebilir.

KAYNAKLAR

- [1] **Xu, J., & Qiu, C.** (2018). Worldwide economic costs and societal burden of dementia. *Neuromethods*, 137, 3–13.
- [2] **Nalçakan, Y.** (2018). *Derin öğrenme ile alzheimer hastalığının teşhisi*. İstanbul Üniversitesi.
- [3] **Association, A.** (2022). Alzheimer's Association. 2022 Alzheimer's Disease Facts and Figures
- [4] **Matthews, K. A., & oth.** (2019). Racial and ethnic estimates of Alzheimer's disease and related dementias in the United States (2015-2060) in adults aged ≥ 65 years. *Alzheimer's & Dementia: The Journal of the Alzheimer's Association*, 15(1), 17–24.
- [5] **Fuller, S. J., Carrigan, N., Sohrabi, H. R., & Martins, R. N.** (2019). Current and Developing Methods for Diagnosing Alzheimer's Disease. *Neurodegeneration and Alzheimer's Disease: The Role of Diabetes, Genetics, Hormones, and Lifestyle*, 43–87.
- [6] **Atalar, A.** (2022). 3b MRI ve hasta bilgileri kullanarak derin öğrenme ile alzheimer hastalığının erken teşhisi. Eskişehir Osmangazi Üniversitesi.
- [7] **Ittner, L. M., & Götz, J.** (2011). Amyloid- β and tau--a toxic pas de deux in Alzheimer's disease. *Nature Reviews. Neuroscience*, 12(2), 67–72.
- [8] **Goenka, N., & Tiwari, S.** (2021). Deep learning for Alzheimer prediction using brain biomarkers. *Artificial Intelligence Review*, 54(7), 4827–4871.
- [9] **Ginat, D. T., & Gupta, R.** (2014). Advances in computed tomography imaging technology. *Annual Review of Biomedical Engineering*, 16, 431–453
- [10] **Zena, J. I., Lucky, E., Ellaine, C. G., Edbert, I. S., & Suhartono, D.** (2022). Deep Learning Approach based Classification of Alzheimer's Disease Using Brain MRI. *2022 5th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 397–402.
- [11] **TÜRK, Ö.** (2022). MR görüntülerinden Alzheimer tespitinde boyut azaltma ve derin öğrenme yaklaşımlarının karşılaştırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(3), 485–491.
- [12] **Menagadevi, M., Mangai, S., Madian, N., & Thiyagarajan, D.** (2023). Automated prediction system for Alzheimer detection based on deep residual autoencoder and support vector machine. *Optik*, 272, 170212.
- [13] **Singh, P., & Mishra, S. K.** (2022). Alzheimer's Detection And Categorization using a Deep-Learning Approach. *Proceedings of the 2022 3rd International Conference on Intelligent Computing, Instrumentation and Control Technologies: Computational Intelligence for Smart Systems, ICICICT 2022*, 727–734.2022.
- [14] **Cheung, C. Y., & oth.** (2022). A deep learning model for detection of Alzheimer's disease based on retinal photographs: a retrospective, multicentre case-control study. *The Lancet Digital Health*, 4(11), e806–e815.
- [15] **Sharma, S., & oth.** (2022). Transfer learning-based modified inception model for the diagnosis of Alzheimer's disease. *Front in Computational Neuroscience*, 16.

- [16] **Shu, F., & Tian, L.** (2018). Deep Learning Methods for Alzheimer's Disease Prediction. In *CS230: Deep Learning, Winter 2018, Stanford University, CA*.
- [17] **Sathish Kumar, L., & oth.** (2022). AlexNet approach for early stage Alzheimer's disease detection from MRI brain images. *Materials Today: Proceedings*, 51, 58–65.
- [18] **Bai, T., Du, M., Zhang, L., Ren, L., Ruan, L., Yang, Y., Qian, G., Meng, Z., Zhao, L., & Deen, M. J.** (2022). A novel Alzheimer's disease detection approach using GAN-based brain slice image enhancement. *Neurocomputing*, 492, 353–369.
- [19] **Kong, Z., Zhang, M., Zhu, W., Yi, Y., Wang, T., & Zhang, B.** (2022). Multi-modal data Alzheimer's disease detection based on 3D convolution. *Biomedical Signal Processing and Control*, 75, 103565.
- [20] **Kapadnis, M. N., Bhattacharyya, A., & Subasi, A.** (2023). Artificial intelligence based Alzheimer's disease detection using deep feature extraction. *Applications of Artificial Intelligence in Medical Imaging*, 333–355.
- [21] **Xu, X., Lin, L., Sun, S., & Wu, S.** (2023). A review of the application of three-dimensional convolutional neural networks for the diagnosis of Alzheimer's disease using neuroimaging. *Reviews in the Neurosciences*.
- [22] **Lanjewar, M. G., Parab, J. S., & Shaikh, A. Y.** (2022). Development of framework by combining CNN with KNN to detect Alzheimer's disease using MRI images. *Multimedia Tools and Applications*, 82(8), 12699–12717.
- [23] **Toğaçar, M., Cömert, Z., & Ergen, B.** (2021). Enhancing of dataset using DeepDream, fuzzy color image enhancement and hypercolumn techniques to detection of the Alzheimer's disease stages by deep learning model. *Neural Computing and Applications*, 33(16), 9877–9889.
- [24] **Liu, Y., Tang, K., Cai, W., Chen, A., Zhou, G., Li, L., & Liu, R.** (2022). MPC-STANet: Alzheimer's Disease Recognition Method Based on Multiple Phantom Convolution and Spatial Transformation Attention Mechanism. *Frontiers in Aging Neuroscience*, 14, 530.
- [25] **Sharma, S., Gupta, S., Gupta, D., Altameem, A., Saudagar, A. K. J., Poonia, R. C., & Nayak, S. R.** (2022). HTLML: Hybrid AI Based Model for Detection of Alzheimer's Disease. *Diagnostics 2022, Vol. 12, Page 1833*, 12(8), 1833.
- [26] **Ismail, W. N., Fathimathul, F. R., & Ali, M. A. S.** (2023). A Meta-Heuristic Multi-Objective Optimization Method for Alzheimer's Disease Detection Based on Multi-Modal Data. *Mathematics 2023, Vol. 11, Page 957*, 11(4), 957.
- [27] **EL-Geneedy, M., Moustafa, H. E. D., Khalifa, F., Khater, H., & Abdelhalim, E.** (2023). An MRI-based deep learning approach for accurate detection of Alzheimer's disease. *Alexandria Engineering Journal*, 63, 211–221. [28] **S. Ahmed et al.**, "Ensembles of Patch-Based Classifiers for Diagnosis of Alzheimer Diseases," *IEEE Access*, vol. 7, pp. 73373–73383, 2019.
- [29] **Seifallahi, M., Mehraban, A. H., Galvin, J. E., & Ghoraani, B.** (2022). Alzheimer's Disease Detection Using Comprehensive Analysis of Timed Up and Go Test via Kinect V.2 Camera and Machine Learning. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 1589–1600.

- [30] **Khan, N. M., Abraham, N., & Hon, M.** (2019). Transfer Learning with Intelligent Training Data Selection for Prediction of Alzheimer’s Disease. *IEEE Access*, 7, 72726–72735.
- [31] **LeCun, Y., Bengio, Y., & Hinton, G.** (2015). Deep learning. *Nature* 2015 521:7553, 521(7553), 436–444.
- [32] **McCulloch, W. S., & Pitts, W.** (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics* 1943 5:4, 5(4), 115–133.
- [33] **Üzen, H.** (2022). *İmalat sistemlerinde derin öğrenme tabanlı doku hata tespiti*. İnönü Üniversitesi.
- [34] **Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- [35] **He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 770–778.
- [36] **Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q.** (2017). Densely connected convolutional networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-January*, 2261–2269.
- [37] **Simonyan, K., & Zisserman, A.** (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- [38] **Bezdan, T. ve Džakula, N. B.** (2019). Convolutional Neural Network Layers and Architectures. *Sinteza 2019-International Scientific Conference on Information Technology and Data Related Research*, 445–451
- [39] **Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z.** (2016). Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 2818–2826.
- [40] **Dubey, S.** (2020). *Alzheimer’s Dataset four class of Images*. www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images
- [41] **Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A.** (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *Thirty-First AAAI Conference on Artificial Intelligence (AAAI-17)*, 4278–4284.
- [42] **Rao, Y., He, L., & Zhu, J.** (2017). A residual convolutional neural network for pan-sharpening. *RSIP 2017 - International Workshop on Remote Sensing with Intelligent Processing, Proceedings*.
- [43] **Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H.** (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*.

ÖZGEÇMİŞ

Ad-Soyad: Eyup HANBAY

ÖĞRENİM DURUMU:

- **Lisans** : 2020, İnönü Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bölümü
- **Yüksek Lisans** : 2020 - Devam etmekte, İnönü Üniversitesi, Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Donanım Anabilim Dalı

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN ÇALIŞMALAR

- **Hanbay, E., Arı, A. (2023).** Özel Blok Yapıları Kullanarak Tasarlanan Derin Öğrenme Mimarileri ile Alzheimer Hastalık Tespiti. Fırat Üniversitesi Mühendislik Bilimleri Dergisi (2023)