T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ALZHEİMER HASTALIĞININ MAKİNE ÖĞRENMESİ TEKNİKLERİYLE İNCELENMESİ

Hudaverdi Emin ELP

YÜKSEK LİSANS TEZİ

Elektronik-Haberleşme Anabilim Dalı

Haberleşme Programı

Danışman

Doç. Dr. Bülent BOLAT

Ocak, 2024

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ALZHEİMER HASTALIĞININ MAKİNE ÖĞRENMESİ TEKNİKLERİYLE İNCELENMESİ

Hudaverdi Emin ELP tarafından hazırlanan tez çalışması 12.01.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik-Haberleşme Anabilim Dalı, Haberleşme Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Bülent BOLAT
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Bülent BOLAT, Danışman
Yıldız Teknik Üniversitesi _____

Doç. Dr. Peyman MAHOUTİ, Üye
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Necdet Tuğrul ARTUĞ, Üye
İstanbul Üniversitesi Cerrahpaşa _____

Danışmanım Doç. Dr. Bülent BOLAT sorumluluğunda tarafımca hazırlanan "ALZHEİMER HASTALIĞININ MAKİNE ÖĞRENMESİ TEKNİKLERİYLE İNCELENMESİ" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Hudaverdi Emin ELP

İmza



Aileme

TEŞEKKÜR

Çalışmamın başından itibaren her zaman olumlu ve destekleyici tutumuyla bana destek olan, teknik alandaki görüşleriyle bu tezi çok daha nitelikli hale getiren ve beraber çalışmış olmaktan büyük mutluluk duyduğum danışman hocam Doç. Dr. Bülent BOLAT' a teşekkür etmeyi borç bilirim.

Hayatım boyunca maddi manevi her türlü desteği bana sağlayan aileme sonsuz teşekkür ederim.

Akdemik olarak çalışmalarıma devam ederken beni teşvik eden ve bana elinden gelen her türlü kolaylığı sağlayan AR-GE müdürüm Sayın Murat PEHLİVAN'a teşekkür etmeyi borç bilirim.

Hudaverdi Emin ELP

İÇİNDEKİLER

TEŞEKKÜR iv
İÇİNDEKİLER v
KISALTMA LİSTESİ vi
ŞEKİL LİSTESİ vii
TABLO LİSTESİ viii
ÖZET ix
ABSTRACT xi
1 GİRİŞ 1
1.1 Alzheimer Hastalığı Ve Belirtileri 1
1.2 Literatür Özeti 3
2 MATERYAL VE METOT 6
2.1 Medikal Görüntüleme Teknikleri 6
2.2 Makine Öğrenmesi Algoritmaları 10
2.3 Evrişimsel Sinir Ağları 13
2.4 Evrişimsel Sinir Ağı (ESA) Modelleri 15
2.5 Transfer Öğrenimi (TÖ) 17
2.7 Alzheimer Hastalığı Veri Setleri 18
3 UYGULAMA 20
3.1 Kullanılan Veri Seti 20
3.2.Kullanılan Donanım 21
3.3 Kullanılan Yazılım 22
3.4.Kullanılan Ağlar ve Önerilen yöntem 25
4 BULGULAR 27
5 SONUÇ 34
KAYNAKÇA 36

KISALTMA LİSTESİ

AH	Alzheimer Hastalığı
ESA	Evrişimsel Sinir Ağı
MRG	Manyetik Rezonans Görüntüleme
DVM	Destek Vektör Makinesi
KNN	K-En Yakın Komşular Algoritması
BT	Bilgisayarlı Tomografi
DP	Doğru Pozitif
DN	Doğru Negatif
YP	Yanlış Pozitif
YN	Yanlış Negatif

ŞEKİL LİSTESİ

Şekil 1.1 Sağlıklı beyin (sol yarı bölge) ve Alzheimer hastası beyin (sağ yarı bölge) **1**
Şekil 2.1 Akciğer kanseri teşhisi için kullanılan BT görüntüsü [20] **7**
Şekil 2.2 KAGGLE Alzheimer veri setinden alınan MRG görüntüsü [25] **8**
Şekil 2.3 İnsan beynine ait PET görüntüsü [24] **9**
Şekil 2.4 Ultrason aletiyle alınan görüntü [22] **10**
Şekil 2.5 Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme ilişkisi **12**
Şekil 2.6 Evrişimli katmanlar **14**
Şekil 2.7 Havuzlama katmanı gösterimi **14**
Şekil 2.8 Tam bağlantılı katman gösterimi **15**
Şekil 2.9 Inception V3 gösterimi [43] **16**
Şekil 2.10 EfficientNet ile ölçeklendirilmiş modeller [45,46] **17**
Şekil 2.11 Transfer öğrenimi yöntemini gösteren resim [50] **18**
Şekil 3.1 Inception V3 modeli transfer öğrenimi gösterimi **26**
Şekil 3.2 EfficientNet B0V2 modeli transfer öğrenimi gösterimi **26**
Şekil 4.1 EfficientNet B0V2 modeli için doğruluk grafiği [63] **27**
Şekil 4.2 EfficientNet B0V2 modeli kayıp grafiği [63] **28**
Şekil 4.3 Inception V3 modeli için doğruluk grafiği [63] **28**
Şekil 4.4 Inception V3 modeli için kayıp grafiği [63] **29**

TABLO LİSTESİ

Tablo 1.1 AH evreleri ve evrelere göre hastaların göstermiş olduğu semptomlar [5] **2**

Tablo 1.2 Literatürdeki çalışmaların doğruluk yüzdeleri [63] **5**

Tablo 3.1 Çalışmada kullanılan Kaggle veri setine ait sınıflar ve örnek resimleri gösteren tablo [25] **21**

Tablo 3.2 Derin Öğrenme için kullanılabilir Framework'ler [39] **22**

Tablo 3.3 Derin Öğrenme için kullanılabilir Framework'ler [39] (devamı) **23**

Tablo 4.1 EfficientNet B0V2 modeli sınıf dağılımı [63] **29**

Tablo 4.2 Inception V3 modeli sınıf dağılımı [63] **30**

Tablo 4.3 Sağlıklı sınıfına göre karışıklık matrisi dağılımı **30**

Tablo 4.4 Çok Hafif sınıfına göre karışıklık matrisi dağılımı **31**

Tablo 4.5 Hafif sınıfına göre karışıklık matrisi dağılımı **31**

Tablo 4.6 Orta sınıfına göre karışıklık matrisi dağılımı **31**

Tablo 4.7 EfficientNet B0V2 modeli performans çıktıları [63] **32**

Tablo 4.8 Inception V3 modeli performans çıktıları [63] **33**

ÖZET

Alzheimer Hastalığının Makine Öğrenmesi Teknikleriyle İncelenmesi

Hudaverdi Emin ELP

Elektronik - Haberleşme Anabilim Dalı

Haberleşme Programı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Bülent BOLAT

Beyindeki sinir hücrelerinin yapısının bozulmasıyla ortaya çıkan Alzheimer Hastalığı hastalıktan etkilenen kişilerin yaşamlarını olumsuz yönde etkileyecek unutkanlık ve algısal problemler yaşanmasına yol açmaktadır. Bu hastalığın ortaya çıktığı dönem genellikle ileri yaşlardır. Gün geçtikçe Alzheimer Hastalığı tedavisi için ayrılan bütçenin artacağı öngörülmektedir. Alzheimer Hastalığı tam anlamıyla tedavi edilerek hastanın eski sağlıklı günlerine dönmesi sağlanamayacak olsa bile hsatalığın ilerlemesi yavaşlatılarak hastanın mümkün olan en uzun süre boyunca bilişsel olarak daha az etkilenerek yaşamını sürdürmesi hedeflenmektedir. Günümüz dünyasında kendine git gide daha fazla yer edinen Yapay Zeka ve Yapay Zekanın ileri alt disiplini olan Derin Öğrenme bu probleme uygulanarak Alzheimer Hastalığının sınıflandırılması ile ilgili bir çalışma yapılmıştır. Çalışma kapsamında Kaggle web sitesinde genel erişime açık olan 2 boyutlu ve 4 sınıfa ait görüntülerden oluşan bir veri seti kullanılmıştır. Veri elde edilmesinin az veri bulunması, uzman tarafından teşhis gerekmesi gibi nedenlerle zor olduğu senaryolarda iyi sonuç verebilen Transfer Öğrenimi metodu kullanılarak Inception V3 ve EfficientNet B0V2 modelleri önceden eğitilmiş modelin ağırlıklarıyla eğitilmiştir. Çok kısa bir eğitim süresi ile Inception V3 modeli için %99.96 EfficientNet B0V2 için %98.23

doğruluk değerleri elde edilmiştir. Eğitim sonucunun açık bir şekilde gözlemlenebilmesi için karışıklık matrisleri sınıflara göre oluşturulmuş ve performans çıktıları hesaplanmıştır. Bu çalışmanın sonuçları Transfer Öğrenimi metodunun Alzheimer Hastalığı tespitinde hızlı ve doğruluk payı yüksek olan kullanışlı bir teknik olduğunu göstermiştir.

Anahtar Kelimeler: Alzheimer Hastalığı, Derin Öğrenme, Transfer Öğrenimi, Makine Öğrenmesi

ABSTRACT

Diagnosis Of Alzheimer's Disease By Using Machine Learning Approaches

Hudaverdi Emin ELP

Department of Electronics – Communication

Communication Programme

Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Bülent BOLAT

Alzheimer's Disease, which is caused by the deterioration of the structure of nerve cells in the brain, leads to forgetfulness and perceptual problems that will negatively affect the lives of those affected by the disease. The period when this disease occurs is usually in advanced ages. It is predicted that the budget allocated for the treatment of Alzheimer's Disease will increase day by day. Even if Alzheimer's Disease cannot be fully treated and the patient will not be able to return to his/her old healthy days, it is aimed to slow down the progression of the disease and to maintain the patient's life with less cognitive impairment for the longest possible time. A study on the classification of Alzheimer's Disease has been carried out by applying deep learning, which is an advanced sub-discipline of artificial intelligence and artificial intelligence, which is gaining more and more place in today's world. In order to access the datasets, a dataset consisting of 2-dimensional images of 4 classes, which are available on the widely preferred Kaggle website, was used. InceptionV3 and EfficientNetB0V2 models were trained with the weights of the pre-trained model using the Transfer Learning method, which can give good results in scenarios where data acquisition is difficult due to reasons such as low data availability and the need for expert diagnosis. With a very short training time, accuracy values of 99.96% for InceptionV3 model and 98.23% for EfficientNetB0V2 were obtained. In order to clearly observe the training result, confusion matrices were created according to the

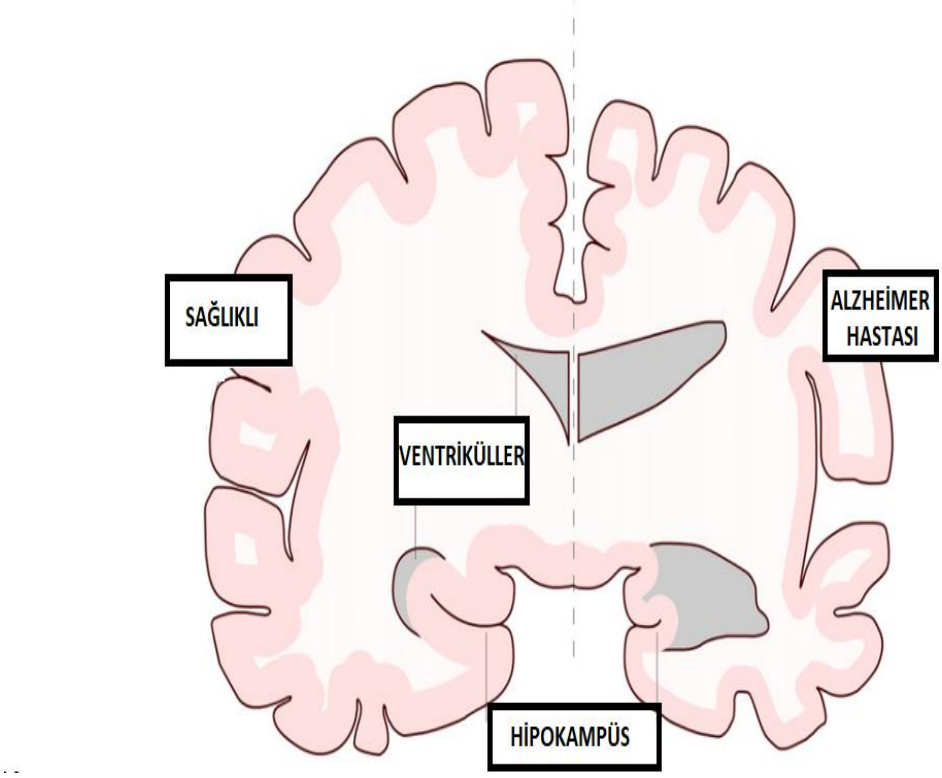
classes and performance outputs were calculated. The results of this study show that Transfer Learning is a fast and accurate technique for Alzheimer's Disease detection.

Keywords: Alzheimer's Disease, Deep Learning, Transfer Learning, Machine Learning

1
GİRİŞ

1.1 Alzheimer Hastalığı Ve Belirtileri

Alzheimer Hastalığı (AH), nörodejeneratif bir hastalıktır. Hastalığın seyri sırasında hafıza kaybı, bilişsel bozulma, davranış değişiklikleri gibi birtakım rahatsızlıklar gözlenir ve en sonunda ölümle sonuçlanır [1]. AH, demansın nedenleri arasında en yaygın görülenlerin başında gelmektedir. 2050 yılına gelindiğinde 150 milyonu aşkın insanın bu hastalıktan etkilenmiş olacağı öngörülmektedir [2]. Dünyadaki demans türlerinin %60 - %80 kadarının AH kaynaklı olduğu düşünülmektedir. Her geçen üç saniyede bir kişi daha demansa yakalanmaktadır [3]. AH'nın Manyetik Rezaonans Görüntüleme (MRG) ile gözlenebilen en belirgin özelliklerine bakıldığında serebral korteksin ve hipokampüsün küçülmesi, ventriküllerin genişlemesi gözlemlenmektedir [4]. Şekil 1.1'de sağlıklı ve Alzheimer hastası kişiler için beynin form değişikliğine uğramış bölümleri görülmektedir.



Şekil 1.1 Sağlıklı beyin (sol yarı bölge) ve Alzheimer hastası beyin (sağ yarı bölge)

AH tıbbi olarak incelendiğinde 7 evre gözlemlenmektedir. Bu evreler ve evrelere göre hastanın gösterdiği semptomlar Tablo 1.1'de gösterilmiştir.

Tablo 1.1 AH evreleri ve evrelere göre hastaların göstermiş olduğu semptomlar [5]

Evre 1	Hastada bilişsel zayıflık görülmeye başlamıştır. Başlangıç evresi olan bu evrede merkezi sinir sisteminde çeşitli patolojik süreçlerin gelişmekte olduğu bilinmektedir.
Evre 2 : Çok hafif bilişsel zayıflık	İletişim becerilerinin bozulmamasına rağmen hastalar anahtar ve cüzdan gibi objelerin yerlerini unutmaya başlamaktadırlar.
Evre 3: Hafif bilişsel zayıflık	Hastalar konuşma sırasında kelime seçimlerinde ve tanıdıklarının isimlerini hatırlamakta zorlanmakta, sıklıkla eşyalarını kaybetmektedirler. Bu evredeki hastaların plan yapma ve organizasyon becerileri azalmıştır.
Evre 4: Orta bilişsel zayıflık	Kısa süreli hafızada sorunlar görülmektedir. Kişisel geçmiş ile ilgili bellek zayıflıkları görülmektedir. Hastalar sosyal konularda içe dönük davranış sergiler.
Evre 5: Orta-şiddetli bilişsel zayıflık/Erken dönem demans	Hastalar bulundukları yer ve zaman hakkında zihinsel karışıklık yaşamaktadırlar. Bu evredeki hastalar günlük aktiviteler için yardıma ihtiyaç duymaktadırlar. Önemli detayları hatırlamakta zorlanmaktadırlar.
Evre 6: Şiddetli bilişsel zayıflık/ Orta dönem demans	Konuşmaları sırasında kelime seçmekte zorlanılmaktadır. Konuşma becerilerinde kayıplar gözlenmektedir. Hastalara günlük aktiviteleri için daha fazla yardım gerekmektedir.
Evre 7: Çok şiddetli bilişsel zayıflık	Hastaların konuşma yetenekleri azalmış ya da kaybolmuştur. Bu evredeki hastalar sürekli olarak bakıma ihtiyaç duymaktadırlar.

1.2 Literatür Özeti

2022 yılında Houria ve arkadaşlarının yapmış olduğu çalışmada MRG ve Difüzyon Tensör Görüntüleme (DTG) verilerinin füzyonuyla AH olan ve olmayan bireyler 2 kategoriye ayrılarak Evrişimsel Sinir Ağı (ESA) ve Destek Vektör Makinesi (DVM) kullanılarak sınıflandırılmış ve %99.79 doğruluğa ulaşılmıştır [6].

Techa ve arkadaşlarının 2022 yılında yaptığı çalışmada ESA tabanlı bir mimari tercih edilmiştir. Bu çalışma için Kaggle'dan elde edilen Beyin MRG veri seti kullanılmıştır. VGG-16, DenseNet196 ve ResNet50 modelleri özellik çıkarmak amacıyla kullanılmıştır. Çalışma %89 doğruluk performansı göstermektedir [7].

Mengadevi ve arkadaşlarının 2023 yılında yapmış olduğu çalışmada AH teşhisi için Kaggle veri seti kullanılmıştır. Histogram eşitleme, eğri eşikleme gibi hibrit yaklaşımlar kullanılarak ön işlemler veri seti üzerinde uygulanmıştır. Otomatik kodlayıcı ve çok ölçekli havuzlama ile beyin beyaz maddesi görüntülerden çıkarılmıştır. Sınıflandırma aşamasında DVM ve K-En Yakın Komşular Algoritması (KNN) kullanılmıştır. Çalışmada %99.77 genel doğruluğa ulaşılmıştır [8].

Sisodia ve arkadaşları bu yıl yaptıkları çalışmada AH aşamalarının tespiti için Transfer Öğrenimi (TÖ) metodunu kullanmışlardır. AH tespitini daha yüksek doğrulukta tespit etmek amacıyla ön işlenmiş ve çoğaltılmış veriler kullanılmıştır. AH ilerlemesinin az olduğu aşamaları sınıflandırmak ve tahmin etmek için derin TÖ modelleri (Xception, VGG19, EfficientNet, DenseNet201, Resnet) uygulanmıştır. Kullanılan modellerden DenseNet201'in %96.59 ile en iyi doğruluğa ulaştığı gözlemlenmiştir [9].

Helaly ve arkadaşları 2022 yılında yaptığı çalışmada medikal görüntüleri AH aşamasına göre sınıflara ayırmak için iki farklı yöntem önermişlerdir. Bu yöntemlerden ilkinde hem 3 boyutlu hem de 2 boyutlu konvolüsyon temelli ADNI kümesinden alınmış medikal görüntüleri kullanan basit ESA mimarileri kullanılmıştır. Kullanılan diğer metotta medikal görüntüler için önceden eğitilmiş modeller kullanılarak TÖ yaklaşımı kullanılmıştır. Yapılan çalışmanın sonucuna bakıldığında ilk yöntemde ESA mimarilerinin hesap karmaşıklığı, uzun zaman harcanması ve bellek tüketimi gibi sorunlarla birlikte 2 boyut ve 3 boyut için

%93,61 ve %95,17 doğruluklarına ulaşılırken önceden eğitilmiş, ince ayarı yapılmış TÖ yöntemi %97'lik doğruluğa ulaşmıştır [10].

Acharya ve arkadaşlarının 2021 yılında yaptığı çalışmada TÖ ve ESA'nı AlexNet, ResNet-50 ve VGG16 modelleriyle AH sınıflandırması yapmışlardır. Bahsedilen çalışmada en iyi sonuç AlexNet modeliyle elde edilmiştir. Ulaşılan doğruluk %95,70 seviyesindedir [11].

Mehmood ve arkadaşlarının 2020 yılında yaptığı çalışmada VGG-16 ağından ilham alarak Siyam ESA modeli geliştirmişlerdir. Veri çoğaltma uygulanarak sınıflar arasındaki dengesiz dağılım ve verilerdeki yetersizlik giderilmeye çalışılmıştır. Yapılan çalışmada sınflandırma işlemi %99.05 doğrulukla gerçekleştirilmiştir [12].

Öziç ve Özşen'in 2020 yılında yaptıkları çalışmada 3 boyutlu veriler kullanılmıştır. Gri ve beyaz madde kayıplarına göre 3 boyutlu görüntüler üzerinden yapılan sınıflandırma sonucunda %92,857 doğruluk gözlemlenmiştir [13].

Liu ve arkadaşlarının 2020 yılında yaptığı çalışmada AH sınıflandırması için bir derin ESA oluşturmuşlardır. Bu görev için 3 Boyuntlu Yoğun Bağlantılı Konvolüsyon Ağları (3B DenseNet) tasarlanmıştır. ESA ve DenseNet modellerinden öğrenilenler AH sınıflandırması için birleştirilmiştir. 97 AH olan, 233 hafif düzeyde, 119 sağlıklı deneyinden toplanan T1 ağırlıklı MRG verileri kullanılmış ve %88,9 doğruluğa ulaşılmıştır [14].

El-Geneedy ve arkadaşlarının bu yıl yaptığı çalışmada iyi sonuçlar vererek başarısını kanıtlamış DenseNet121, EfficientNetB7, InceptionV3, ResNet50, VGG-16 gibi derin öğrenme modelleri karşılaştırılmıştır. InceptionV3 modeli diğer modellerden daha iyi performans göstererek %91,38 doğruluğa ulaşabilmiştir [15].

Murugan ve arkadaşlarının 2021 yılında yaptığı çalışmada AH'nın 4 evresi için yüksek doğrulukta teşhis yapabilecek şekilde önerilen DEMNET modeli %95,23 doğruluğa ulaşmıştır [16].

Yıldırım ve Çınar 2020 yılında yaptıkları çalışmada AH derecelerini 4 kategoride sınıflandırmışlardır. Çalışmada Önerilen hibrit model ResNet50 tabanlıdır. AlexNet, ResNet50, DenseNet201, VGG-16 modelleri sırasıyla %86, %78, %87 ve % 78 doğruluk sonucu vermiştir. Hibrit modelin doğruluğu ise %90 dır [17]. Literatüredeki çalışmaların doğrulukları Tablo 1.2'de gösterilmiştir.

Tablo 1.2 Literatürdeki çalışmaların doğruluk yüzdeleri [63]

Çalışmalar	**Doğruluk**
Houria ve ark. (2022)	%99,79
Techa ve ark. (2022)	%89,00
Menagadevi ve ark. (2023)	%99,77
Sisodia ve ark. (2023)	%96,59
Helaly ve ark. (2022)	%97,00
Acharya ve ark. (2021)	%95,70
Mehmood ve ark. (2020)	%99,05
Öziç ve Özşen (2020)	%92,86
Liu ve ark. (2020)	%88,90
El-Geneedy ve ark. (2023)	%91,38
Murugan ve ark. (2021)	%95,23
Yıldırım ve Çınar (2020)	%90,00

2
MATERYAL VE METOT

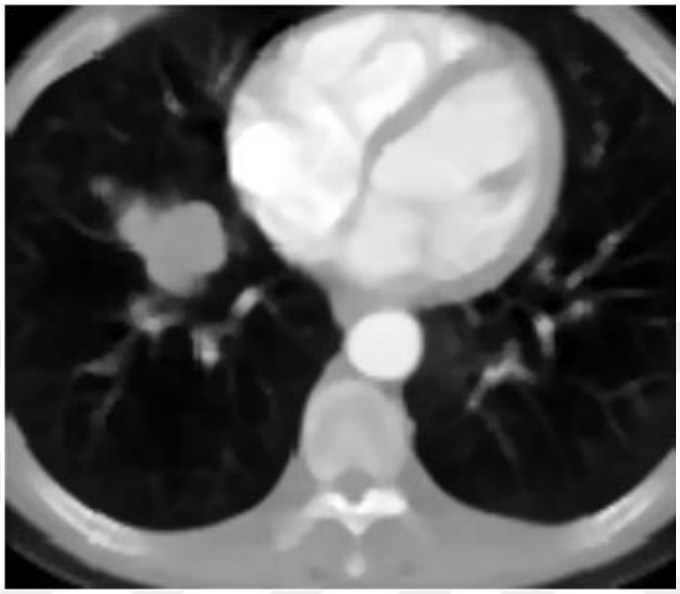
2.1 Medikal Görüntüleme Teknikleri

Günümüzde tıbbi alanda görüntüleme teknikleri hastalıkların teşhisinde önemli yardımcılardır. AH teşhisi için çeşitli görüntüleme teknikleri kullanılabilmektedir. Yapılan tez çalışmasında AH, MRG tekniği kullanılarak 4 sınıfa ayrılmış bir veri seti üzerinden sınıflandırılmıştır. Başlıca medikal görüntüleme teknikleri alt başlıklar olarak aşağıda verilmiştir.

2.1.1 X-Işını Temelli Görüntüleme

X-Işınları tıbbi alanda sıklıkla kullanılan görüntüleme tekniklerinin temelinde bulunmaktadır. Radyografi, Floroskopi, Mamografi ve Bilgisayarlı Tomografi (BT), X-ışınları temelli görüntüleme yöntemleridir. X-Işınları, radyasyon kullanılarak yüksek doğruluklu ve net görüntülerin yakalanması için kullanılır. Yapının görüntülerini oluşturmak ve yapıya nüfuz etmek için elektromanyetik radyasyonun kemik, boşluk ve kas gibi dokular tarafından farklı miktarlarda soğurulması prensibini kullanarak vücuttaki anormalliklerin teşhisinde ve tespitinde rol alırlar [18]. Willhelm Conrad Rontgen tarafından bulunan radyografi tarihteki ilk tıbbi görüntüleme yöntemidir. Radyogram görüntüler, kırıklar ve kanserli dokuların tespiti alanlarında kullanılmaktadır. Floroskopi ise X-ışınlarıyla alınan görüntünün belli bir süre alınmasıyla anatomik hareketlerin gözlenmesine katkı sağlar. Mamografi özelleştirilmiş bir X-Işını tekniğidir ve radyografiye kıyasla çok daha az miktarda radyasyona maruz bırakır. Meme kanseri teşhisinde kullanılır. BT'ye olan ihtiyaç röntgende çekim yapılan bölgenin tek boyutta görünmesi ve derinlik özelliğinden yoksun olması prensibinden ortaya çıkmıştır. BT yöntemi hastanın etrafında X-Işını ile kesit alınması ve algoritmik olarak birleştirilerek daha ayrıntılı görüntüleme sağlanmaktadır. 3 Boyutlu BT görüntüleri kitlelerin teşhisinde önemli rol oynamaktadır. BT'nin faydaları ağrısız ve hızlı bir metot olması, küçük ayrıntıları iyi teşhis etmesi ve iyi çözünürlükrte olması şeklindedir. BT'nin dezavantajları X-Işınına maruz kalınması nedeniyle kansere yol açabilecek riskler taşıması, tam olarak gerçek zamanlı uygulama verememesi ve kontrast özelliklerle teşhis edilemeyecek olan alerji gibi durumları

saptayamamasıdır. BT'nin kullanıldığı uygulamalara bakılırsa beyin, sinüs, diş hastalıkları, omuz, kalça, bilek gibi vücudun çeşitli bölgelerini incelemeye imkan sağlamaktadır. Kanser tedavisi gibi süreçlerin izlenmesine yardımcı olmaktadır. Travma ve hastalıkları incelemeye katkı sağlamaktadır [19]. Şekil 2.1'de akciğer kanseri teşhisi için kullanılan BT görüntüsü verilmiştir.

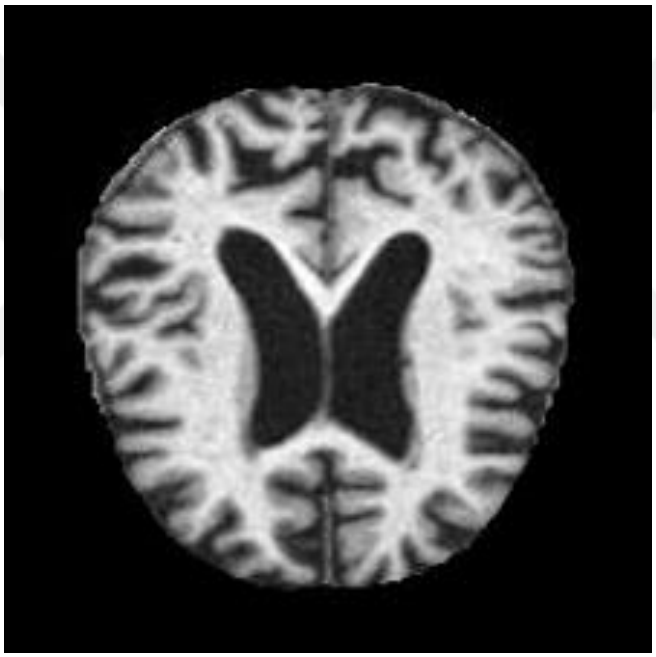


Şekil 2.1 Akciğer kanseri teşhisi için kullanılan BT görüntüsü [20]

2.1.2 Manyetik Rezonans Görüntüleme (MRG)

MRG insan üzerinde ilk defa 1976 yılında bir insan parmağının Peter Mansfield ve arkadaşları tarafından görüntülenmesiyle insanlar üzerinde kullanılmaya başlanmıştır. 1980 yılına gelindiğinde ise insan beyninin MRG görüntüsü alınmıştır [21]. MRG'de vücuttan görüntüler elde edilirken manyetik alan ve radyo frekans alanları kullanılmaktadır. MRG dokulardaki proton yoğunluğu ve manyetik alanla hizalanan atomların ilk konumlarına yönelme zamanlarındaki değişiklikleri saptamaktadır [22]. MRG cihazlarında üretilen manyetik alan dünyanın manyetik alanının 10 ila 60 bin katı olarak uygulanmaktadır. MRG için hasta hidrojen ile soğutulan süper iletken içinde yüksek manyetik alana maruz bırakılmaktadır. Hasta etrafına yerleşik halde bulunan antenler radyo dalgaları yayarken diğer taraftan vücuttaki protonlar tarafından dalgalar soğurulur. Manyetik alan kuvveti ayarlanarak proton rezonans fonksiyonu da değiştirlmektedir. Bunun temelinde manyetik alan ile frekansın doğrusal bir ilişki eğrisine sahip olması prensibinden faydalanılmaktadır [19]. Omurilik yaralanması, bağ ve tendon yaralanması, beyin

tümörleri gibi yumuşak dokularda zede yaralanma ve kopuk teşhisi için kullanımı uygundur. Farklı yumuşak doku türleri arasındaki ince ayrıntıları gösterir [23]. AH'den en erken evrelerden itibaren olumsuz etkilenen organların başında gelen korteks ve hipokampüs bölgeleri MRG görüntülerinden faydalanılarak ayırt edilebilmektedir [24]. MRG'nin avantajları vücuda girmeden (non-invazif) ve acısız olarak çekimin yapılması, iyonlaştırıcı radyasyon etkisinin olmaması, yüksek çözünürlüklü çekim yapması ve yumuşak doku kontrastını iyi yansıtması olarak gösterilmektedir. Göreli olarak düşük hassasiyetli olması, uzun tarama ve işlenme süreleri ve maliyetinin yüksek olması MRG'nin dezavantajlı taraflarıdır [22]. Şekil 2.2'de AH'li bir bireyden alınan beyin MRG görüntüsü verilmiştir.

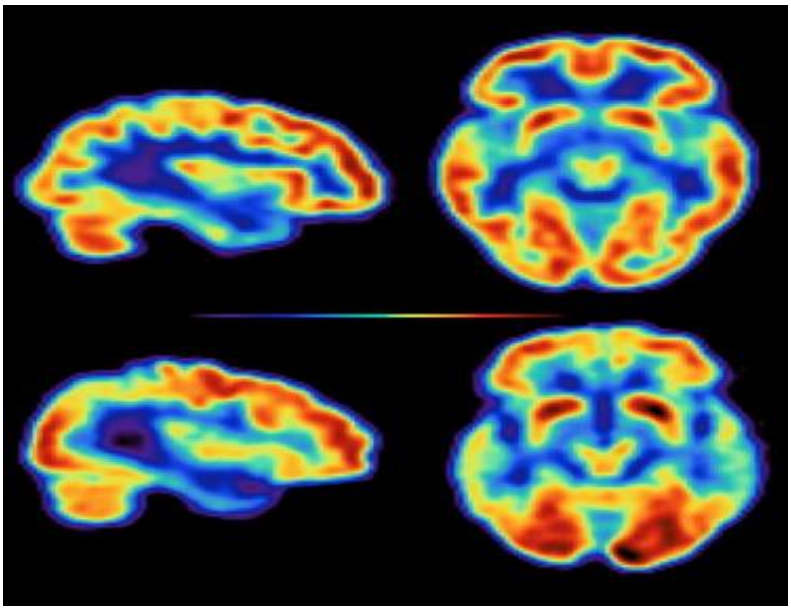


Şekil 2.2 KAGGLE Alzheimer veri setinden alınan MRG görüntüsü [25]

2.1.3 Pozitron Emisyonu Tomografisi (PET)

Antoine Henri Becquerel radyasyon emisyonunu 1896 yılında keşfetmiştir. Nükleer tıp alanında 1930 lu yıllardan itibaren çeşitli izotoplar kullanılmaktadır. Radyofarmasötik izotoplar vücuda verildiğinde, maddeler vücuttaki belli bölgelere toplanır. Radyoaktif madde soğurulduğunda özel alıcıların algılayabildiği bir radyasyon açığa çıkar. Bilgisayar yardımıyla görüntüye çevirme gerçekleştirilir [21]. Antoine Henri Becquerel radyasyon emisyonunu 1896 yılında keşfetmiştir. Nükleer tıp alanında 1930 lu yıllardan itibaren çeşitli izotoplar kullanılmaktadır. Karbon (C) 11 izotopu yaklaşık 20 dakika, Azot(N) 13 izotopu yaklaşık 10 dakika,

Oksijen 15 izotopu yaklaşık 2 dakika ve Flor (F) 18 izotopu yaklaşık olarak 110 dakika yarılanma ömrü özelliklerine sahiptirler. Kısa yarılanma ömürleri olan izotoplar kullanılarak gama radyasyonunun tespiti prensibiyle çalışan PET vücuttaki antikor, yağ aside ve glikoz gibi yapılarla birleşerek vücuttaki aktif süreçlerin görselleştirilebilmesine olanak sağlar. Radyofarmasötik izotoplar vücuda verildiğinde, maddeler vücuttaki belli bölgelere toplanır. Radyoaktif madde soğurulduğunda özel alıcıların algılayabildiği bir radyasyon açığa çıkar. Bilgisayar yardımıyla görüntüye çevirme gerçekleştirilir. Görüntüleme sisteminin kalitesi, sistem çözünürlüğü, görüntü alınan organdaki tutulma derecesi, kullanılan izotop ve PET kamerasının özellikleriyle doğru orantılı olarak değişir [26]. Bahsedilen görüntüleme yönteminin avantajları değerlendirilirse yüksek doğruluklu ve ayrıntılı çıktılar verir. Kanserin ne kadar yayıldığını ve tedavisinin nasıl izlediğini gösterebilir. Dokuya özgü kontrastları iyi algılar. Görüntülenen sistem veya yapının bütüncül bir yaklaşımla incelenmesine olanak sağlar. Olumsuz tarafları, düşük olarak değerlendirilebilecek bir çözünürlüktedir. Radyoaktif izotopların ve ekipmanların kullanılması maliyeti yükseltmektedir. Radyoaktif maddelerin kullanımı nedeniyle ekstra dikkat gerekmektedir. Kullanıldığı uygulamalar ise çeşitli kanserlerin teşhisi, uygulanan tedavinin etkinliğinin değerlendirilmesi, AH, Parkinson Hastalığı ve Epilepsi şeklindedir [22]. Şekil 2.3'de insan beynine ait PET görüntüsü verilmiştir.



Şekil 2.3 İnsan beynine ait PET görüntüsü [24]

2.1.4 Ultrason

Ultrason II. Dünya Savaşı yıllarında radar ve sonar teknolojilerinin paralelinde gelişmiş bir görüntüleme yöntemidir. Tıbbi görüntüleme teknikleri içinde en ekonomik olanlardandır. 30 kHz ile 500 MHz frekans aralığında çalışırlar [21]. Ses dalgalarının yayılması ve yankı olarak geri gelişinin görsel olarak ifadesi olan bir görüntüleme metodudur. Ultrasonun avantajlı tarafları ağrısız ve radyasyonsuz olması, gerçek zamanlı bilgi aktarımı ve yüksek çözünürlüklü görüntüleme yapmasıdır. Dezavantajları ise operatöre bağlı görüntüleme yapması, zaman alan bir teknik olması ve suya olan doygunluk (hidrasyon) durumundan etkilenmesidir. Sağlık alanında kullanıldığı yerler ise lenf, tiroid ve paratiroid gibi baş ve boyundaki yapıların görüntülenebilmesi, hamilelik sırasında fetüsün gözlemlenmesi, karın içi organların gözlemlenebilmesinin yanında kalp ve işlevlerini gözlemlemek için kullanılan ekokardiyografi için kullanılır [22]. Şekil 2.4'te örnek bir ultrason görüntüsü verilmiştir.



Şekil 2.4 Ultrason aletiyle alınan görüntü [22]

2.2 Makine Öğrenmesi Algoritmaları

Günümüzde artma eğiliminde olan ve gelecekte çok daha fazla kullanılacağı öngörülebilen makine öğrenmesi ve derin öğrenme algoritmaları, bilgisayarların karar verme ve tahmin etme için kullanılabilecek uzman sistemlerin önemli bir bileşenidir. Makine öğrenmesi sistemin yapması gereken işin spesifik olarak

belirtilmese de öğrenme yeteneği sağlayan bir alandır. Bir makine öğrenmesi türü olan derin öğrenme ise sistemlerin bir gerçeklik kazanmasına ve gerçek dünyayı kavramasına olanak sağlamaktadır [27].

2.2.1 Denetimli (Supervised) Öğrenme

Denetimli öğrenmede girdi için örnekleri kapsayan bir veri seti gerekmektedir ve yardım gerektiren bir algoritma kullanır. Girdiler, sınıflandırma yöntemleri kullanılarak eğitim ve test veri kümeleri altında farklı sınıflara dağıtılır. Alınan çıktı, eğitim veri tabanından tahmin edilir veya sınıflandırılır. Algoritmalar, veri tabanını eğitirken bazı şekilleri öğrenmeye çalışır ve test veri tabanı üzerinde performansını gösterir. Model eğitildikten sonra tahmin edilen çıktısı, gerçek çıktı ile karşılaştırılır [27, 28, 29, 30].

2.2.2 Denetimsiz (Unsupervised) Öğrenme

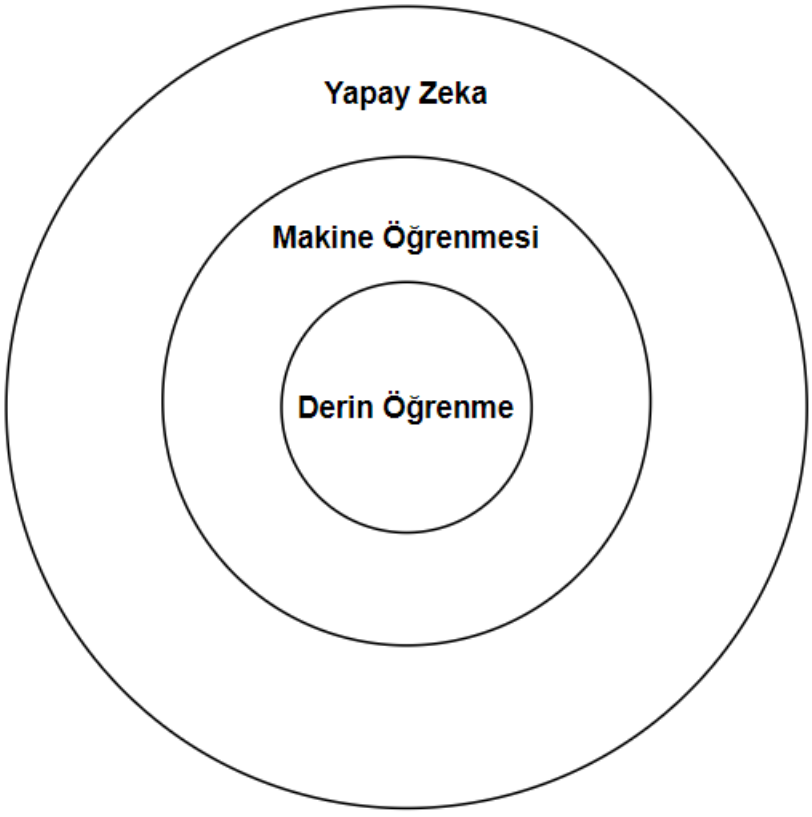
Denetimsiz öğrenmede sistem, veri setlerini baz alarak eğitim yapmak yerine kararı kendi başına verecektir. Denetimli öğrenmenin aksine doğru cevap ve öğretici olmadığı için bu algoritmaya denetimsiz öğrenme denir. Algoritmalar, verilerdeki özellikleri yakalamak ve keşfetmek için özgür bırakılmıştır. Denetimsiz öğrenme algoritmalarının verilerden öğrendiği özellikler çok kısıtlıdır. Gruplandırmada ana prensibi benzerlik veya yüksek boyutlu bir alandan daha düşük bir alana yansıtılan veri temsilleridir. Genellikle kümeleme ve boyut azaltma için kullanılır [27,28,29,30].

2.2.3 Pekiştirmeli (Reinforcement) Learning

Denetimli ve denetimsiz öğrenme ile birlikte üç temel makine öğrenimi algoritmasından biridir. Pekiştirmeli öğrenme, kazanılan ödülü maksimize etmek için bir ortamda nasıl hareket etmesi gerektiği problemine çözüm bulmaya çalışmaktadır. Deneme yanılma yaparak hedefe kendi başına başarıyla ulaşmayı amaçlamaktadır. Araç sürmek veya bir video oyunu oynamak gibi problemleri çözmede kullanılır. Oyun gibi sanal dünya problemlerinde insan performansının üstüne kolayca ulaşabilmektedir [27, 28, 29, 30].

2.2.4 Derin Öğrenme

Derin sinir ağları, makine öğrenmesinin temeli sinir ağlarına dayanan ileri bir algoritmasıdır. Giriş ve çıkış arasında çeşitli parametrelere ve katmanlara sahip nöronlardan oluşan bir ağ modelidir. Derin Öğrenme, sinir ağı mimarileri yaklaşımını takip eder ve bu nedenle derin sinir ağları denir. Derin Öğrenme, özelliklerin otomatik olarak öğrenilmesini ve bunların çeşitli düzeylerde hiyerarşik bir şekilde temsil edilmesini sağlar. Derin öğrenmenin bu güçlü süreci, onu geleneksel makine öğrenimi yöntemlerinin aksine sağlam kılar; kısacası, özellik çıkarma ve değiştirme işlemi için derin öğrenmenin mimarisi kullanılır. İlk katmanlar, giriş verilerinin basit bir şekilde işlenmesini gerçekleştirir veya kolay özellikleri öğrenir ve bu çıktı, karmaşık özelliklerin öğrenilmesini gerçekleştiren üst katmanlara gider. Bu nedenle derin öğrenme, daha büyük verilerle ve çok daha komplike yapılarla başa çıkmak için uygundur [28]. Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme arasında arasındak ilişki Şekil 2.5'de gösterilmiştir.



Şekil 2.5 Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme ilişkisi

Derin öğrenmenin tarihçesine bakılacak olursa 1943 yılında McCulloch ve Pitts nöronların birleştirilmesiyle oluşturulan Turing makinesini göstermiştir [31]. 1958

yılına gelindiğinde Rosenblatt [32], öğrenmeye çalıştıkları şeyin temsil edilebilmesi durumunda algılayıcıların kesişeceğini göstermiştir. 1969 yılında Minsky ve Papert [33] algılayıcıların dezavantajını ortaya koymuş ve en az on yıl boyunca çalışan nöronların araştırılması askıya alınmıştır. Bundan sonra 1985 yılına gelindiğinde Geoffrey Hinton ve arkadaşları [34] geri yayılım algoritmasını tanıttı. Daha sonra 1988 yılında Neocognitron [35] adı verilen hiyerarşik bir sinir ağı görsel örüntü tanıma yeteneğine sahipti. Ayrıca, 1998 yılında Yan LeCun [36] belge analizi için ESA ile geri yayılımı analiz etmiştir. Ardından, 2006 yılında Hinton laboratuvarı Derin Sinir Ağları için eğitim sorununu çözmüştür [37, 38]. 2012'den 2020'ye kadar çeşitli alanlarda derin öğrenme algoritması giderek gelişmektedir [28].

2.3 Evrişimsel Sinir Ağları

ESA çok katmanlı algılayıcı çeşitlerinden bir tanesidir ve aynı zamana derin öğrenme algoritmalarından biridir. İleri beslemeli yapıdadır ve denetimli sinir ağları sınıfında yer almaktadır. ESA diğer sinir ağlarına benzer şekilde hayvan ve insan beynindeki nöronlar modellenmeye çalışılmıştır. Özellikle bir kedinin beynindeki görme ile ilgili alanı modellemektedir. ESA' nın ilk örneği 1988 yılında LeCun tarafından önerilen LeNet modelidir. ESA'nın kullanılmasıyla hızlı bir öğrenme sağlandığı ve görüntülerle yapılan işlemlerde kendinden önceki yöntemlerden çok daha başarılı olduğu vurgulanmıştır. 2014 yılında düzenlenmiş olan ImageNet yarışmasında çok fazla sayıda resim ve sınıfın bulunduğu devasa bir veri setinin sınıflandırılmasında en iyi dereceleri yapan takımların tamamı ESA tabanlı yapıları geliştirerek kullanmışlardır [39,42].

Bir ESA,

(i) evrişimli katmanlar,
(ii) havuzlama katmanları ve
(iii) tam bağlantılı katmanlar

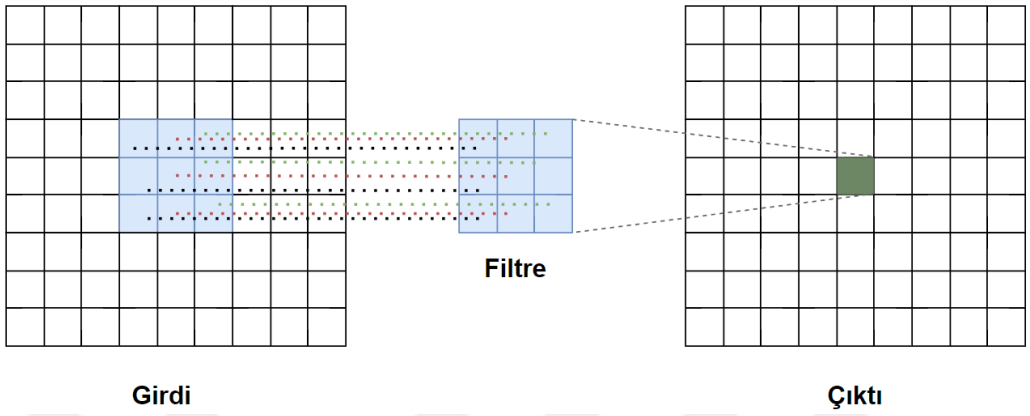
olmak üzere üç ana sinir katmanı türünden oluşur.

Evrişimli katmanlar (Şekil 2.10) özellik haritalarının üretildiği katmanlardır. Evrişim işleminin sağladığı başlıca faydalar;

1) aynı özellik haritasındaki ağırlık paylaşım mekanizması parametre sayısını azaltır.

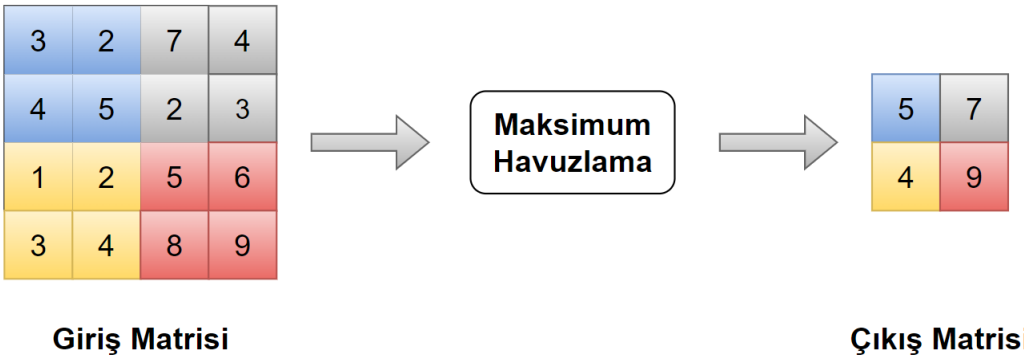
2) yerel bağlantı, komşu pikseller arasındaki ilişkileri öğrenir.

3) nesnenin konumuna göre değişmezdir.



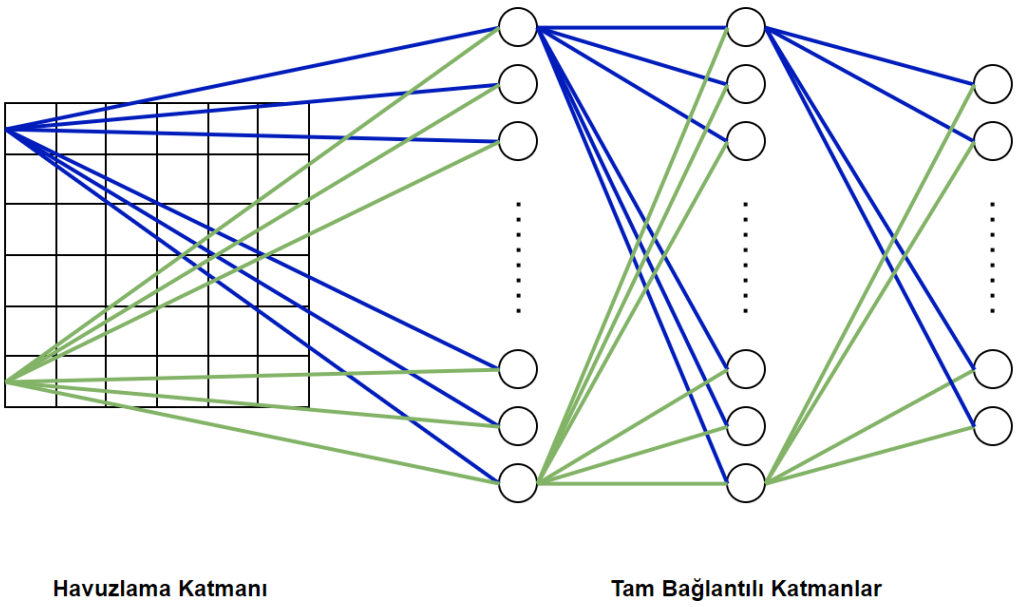
Şekil 2.6 Evrişimli katmanlar

Havuzlama katmanı (Şekil 2.11) boyut azaltmaktan sorumlu olan katmandır. Havuzlama katmanı örnekleme veya alt örnekleme olarak da adlandırılır, çünkü boyutun küçültülmesi eş zamanlı olarak bilgi kaybına yol açar. Ancak bu kayıp ağ için faydalıdır çünkü boyutun küçülmesi, ağın sonraki katmanları için daha az hesaplama yüküne yol açar ve aynı zamanda verileri ezberlemenin (overfit) önüne geçmektedir. Ortalama havuzlama ve maksimum havuzlama en sık kullanılan stratejilerdir.



Şekil 2.7 Havuzlama katmanı gösterimi

Evrişim ve havuzlama katmanının ardından, sinir ağındaki üst düzey akıl yürütme, tam bağlantılı katmanlar (Şekil 2.12) aracılığıyla gerçekleştirilir. Tam bağlantılı bir katmandaki nöronlar, adından da anlaşılacağı gibi, bir önceki katmandaki tüm aktivasyonlarla tam bağlantılara sahiptir. Bu nedenle aktivasyonları, bir matris çarpımı ile hesaplanabilir. Tam bağlı katmanlar sonunda 2 boyutlu özellik haritalarını 1 boyutlu özellik vektörüne dönüştürür. Türetilmiş vektör, sınıflandırma için belirli sayıda kategoriyi belirtmektedir [40,41].



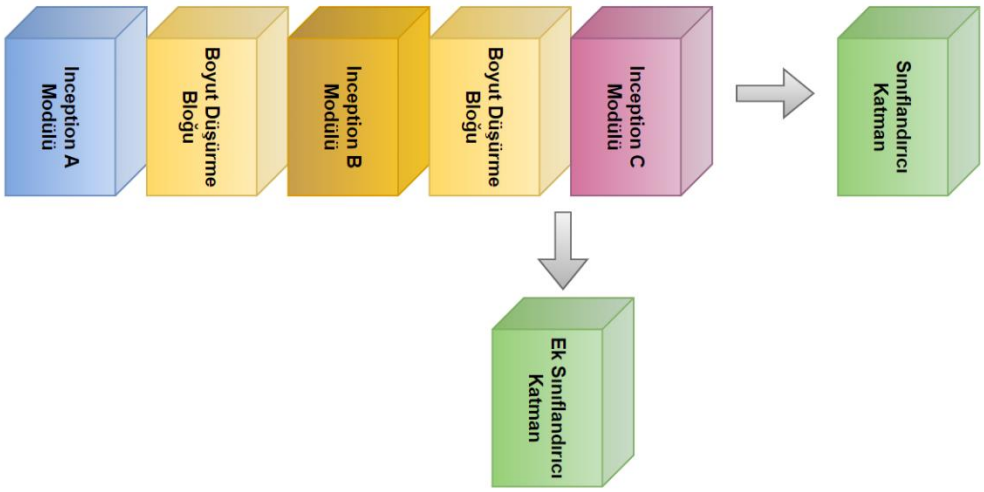
Şekil 2.8 Tam bağlantılı katman gösterimi

2.4 Evrişimsel Sinir Ağı (ESA) Modelleri

Bu bölümde ESA mimarisinin çalışmada kullanılan modelleri tanıtılmıştır. Bu modeller çeşitli katman sayıları ve katman çeşidi konfigürasyonlarıyla yüksek doğrulukta sonuç alınabilen ve çokça tercih edilen ağlardandır.

2.4.1 Inception V3

Inception V3 modeli ImageNet veri kümesi üzerinde iyi sonuç vermiş modellerden bir tanesidir ve görüntü tanıma uygulamalarında yaygın olarak kullanılmaktadır. Inception V3 modeli 42 katmanlı bir derin sinir ağından oluşmaktadır [43]. Inception V3 gösterimi Şekil 2.16'da yapılmıştır.



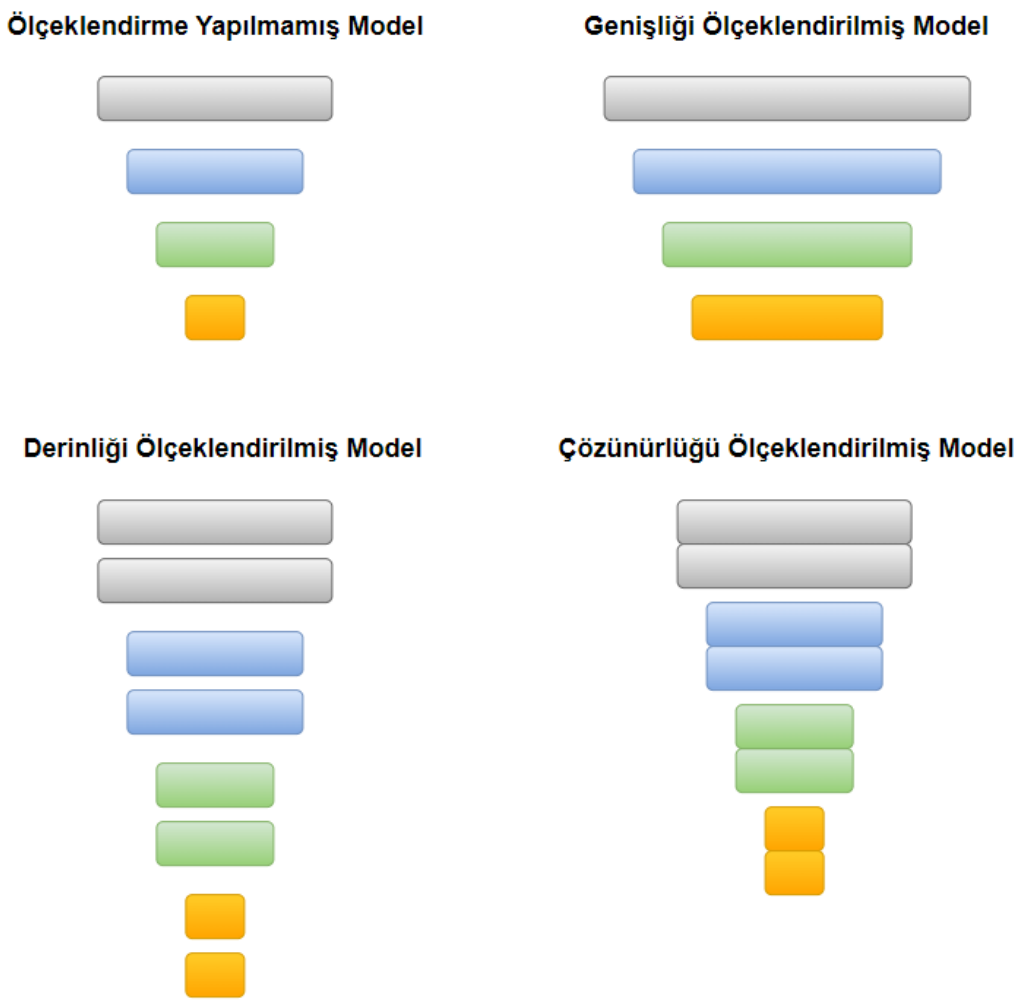
Şekil 2.9 Inception V3 gösterimi [43]

2.4.2 EfficientNet ve EfficientNetV2

ESA, genellikle sabit bir kaynakla beslenir ve daha fazla kaynak varsa daha iyi doğruluğua ulaşabilmektedir. EfficientNet modeliyle model ölçeklendirme sistematik olarak incelenmiş ve ağın derinlik genişlik ve çözünürlüğünün dengelenmesiyle daha iyi performansa ulaşılabileceği belgelenmiştir. Basit ama son derece etkili bir bileşik katsayı kullanılarak derinlik, genişlik ve çözünürlük ölçeklenebilmektedir.

Ölçeklendirilme derecesine göre EfficientNet ağı B0-B7 olacak şekilde sekiz ağ olarak incelenebilmektedir. EfficientNet ağı diğer ağlarla karşılaştırıldığında daha hem daha hızlıdır hem de daha doğru sunuçlar bulmaktadır.

Google şirketi tarafından 2019 yılında önerilen EfficientNet çok boyutlu karma ölçeklendirme teoremi akademik olarak yoğun ilgi görmüştür. Bu ağdan yola çıkılarak hem hız hem de doğruluğu maksimize etmek için ağ genişliği, ağ derinliği ve görüntü çözünürlüğünü aynı anda optimize eden model EfficientNetV2 olarak önerilmiştir. EfficientNet ile kıyaslanığında daha hızlı daha az kaynak kullanan ve daha yüksek doğruluklu bir ağdır. Genişletilmiş, Derinleştirilmiş ve Çözünürlüğü artırılmış ağlar şekilde gösterilmiştir [44]. Ölçeklendirilmiş EfficientNet modelleri Şekil 2.20 ‘de gösterilmiştir [45,46].

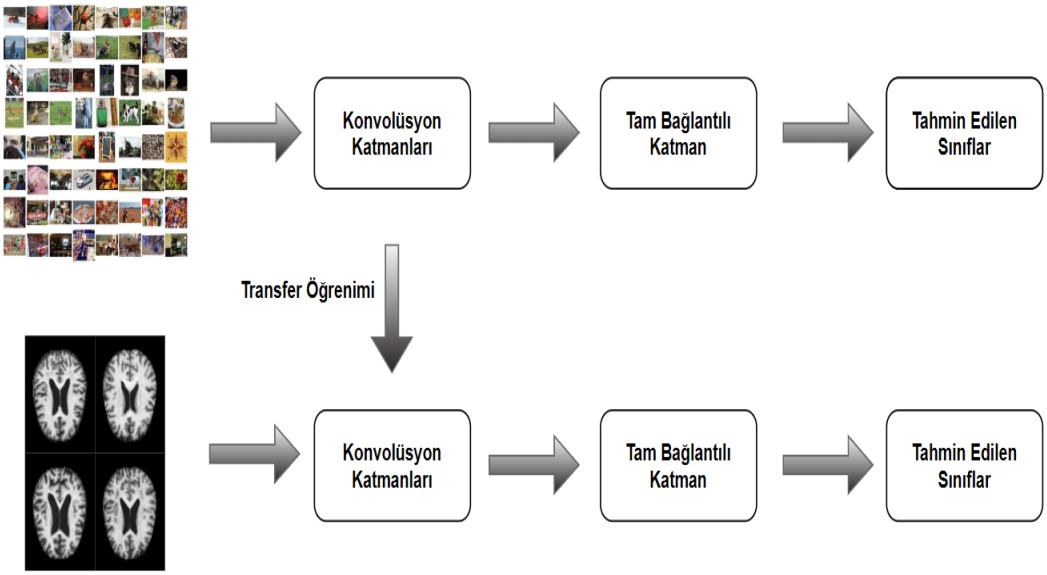


Şekil 2.10 EfficientNet ile ölçeklendirilmiş modeller [45,46]

2.5 Transfer Öğrenimi (TÖ)

Derin öğrenme gerçek hayat problemlerine uygulandığında olumlu sonuçlar vermektedir ve Makine Öğrenmesi'nde büyük bir problem olan özellik çıkarımını otomatik olarak gerçekleştirmektedir. Diğer taraftan Derin Öğrenme algoritmalarının zayıf kaldığı taraf büyük veri setlerinin gerekmesi, eğitimin uzun zaman alması ve çok güçlü hesaplayıcılara ihtiyaç duyulmasıdır. [47] Aynı zamanda medikal alanda kullanılacak veriler yeterli vaka çıkmaması veya kullanılacak görüntüleme tekniğinin masraflı olası gibi sebeplerle kolay temin edilememektedir. Çoğu zaman elde edilmesine rağmen alanında uzman hekim tarafından etiketleme yapılması gerekmektedir. Belirtilen dezavantajlar TÖ'ni önemli bir alternatif haline getirmektedir [48]. TÖ, derin öğrenme için yeterli

büyüklükte verinin olmadığı senaryolarda kullanışlı bir alternatif oluşturmaktadır. TÖ' nde modeller başka modellerin ağırlıklarını kullanır ve gereken küçük modifikasyonlarla hedef problem için hazır hale getirilir. Bu sayede kısa zamanda az veriyle ve dolayısıyla daha düşük güçte hesaplayıcılarla iyi sonuçlar elde edilebilmektedir [49]. Şekil 2.21'de TÖ gösterilmiştir [50].



Şekil 2.11 Transfer öğrenimi yöntemini gösteren resim [50]

2.7 Alzheimer Hastalığı Veri Setleri

AH teşhisi için, yeterli veri bulunduran kullanıma açık olan ve alanında uzman kişiler tarafından etiketlenmiş görüntüler bulunduran veri setleri gerekmektedir. Yapılan araaştırmada belirtilen nitelikleri karşılayabilecek nitelikte olan OASIS-3 veri seti, ADNI veri seti ve Kaggle Alzheimer veri seti bulunmaktadır.

2.7.1 OASIS-3 Veri Seti

OASIS-3, Washington Üniversitesi Knight Alzheimer Hastalığı Araştırma Merkezi'nde 15 yıl boyunca devam eden çeşitli çalışmalardan toplanan 1098 katılımcıya ait MRG ve PET görüntüleme ve ilgili klinik verilerin bir derlemesidir. Katılımcılar arasında bilişsel açıdan normal 605 yetişkin ve yaşları 42 ila 95

arasında değişen, bilişsel gerilemenin çeşitli aşamalarındaki 493 kişi yer alıyor. OASIS-3 veri seti, çoklu yapısal ve fonksiyonel diziler de dahil olmak üzere 2000'den fazla MR kesiti içerir. PET görüntüleme 1500'den fazla ham görüntüleme taraması içerir. OASIS-3 ayrıca hacimsel segmentasyonlar ve PET analizleri gibi sonradan işlenmiş görüntüleme verilerini de içerir. OASIS-3, sağlıklı yaşlanma ve demansla ilgili soruları yanıtlamak için bilim camiasının kullanımına açık erişimli bir veri seti olarak mevcuttur [51].

2.7.2 ADNI Veri Seti

ADNI veri setinin oluşturulmasının arka planında, nörogörüntüleme ölçümleri ve kimyasal biyobelirteçlerin, normal yaşlanma ve Hafif Bilişsel Bozuklukta (HBB) klinik ilerlemenin önemli göstergeleri olabileceği ve ayrıntılı değerlendirilmeleri gerektiği fikri vardır. ADNI veri setinin amacı nörogörüntüleme ve kimyasal biyobelirteçlerin kullanılmasıyla Normal bireyler, HBB olan bireyler ve AH bireyler arasındaki ayrımı yapabilmektir. Veri seti oluşturulurken toplamda 819 kişi (229'u bilişsel olarak normal, 398'i HBB'lu ve 192'si Alzheimer Hastası) başlangıçta kaydedilmiş ve klinik deneyler ve bilişsel fonksiyon ölçümüyle 12 ay boyunca takip edilmiştir. AH, HBB ve Normal bireyler toplanarak sunulmuştur [52].

2.7.3 KAGGLE Alzheimer Veri Seti

KAGGLE' dan alınan Alzheimer veri seti AH'nı 4 sınıf altında toplamıştır. Bu sınıflar Alzheimer Hastası(AH), Hafif Bilişsel Bozukluk, Çok Hafif Bilişsel Bozukluk ve Sağlıklı şeklindedir. Kaggle'dan alınan Alzheimer veri seti 3 boyutlu MRG görüntülerinden elde edilen 2 boyutlu kesitler çıkarılarak oluşturulmuştur ve toplamda 6400 veriden oluşmaktadır [25].

3
UYGULAMA

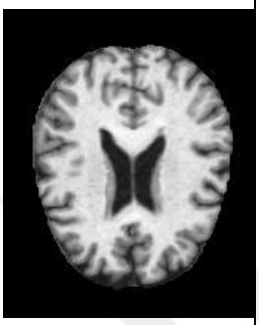
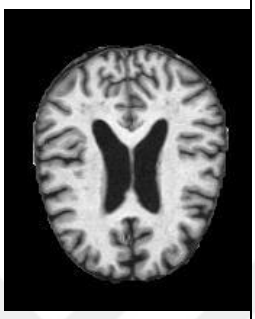
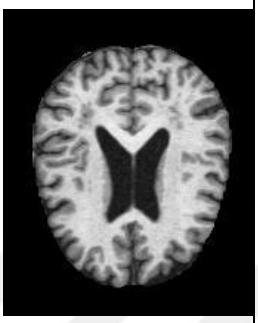
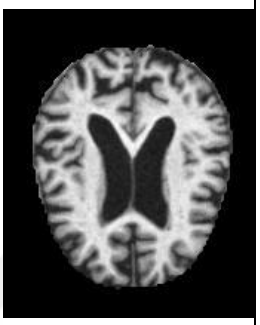
AH' nın beyinde meydana getirdiği yapısal değişikliklere giriş bölümünde değinilmiştir. Bahsi geçen değişiklikleri algılayacak yapının üzerinde çalışacağı veri seti belirlenmiştir. Kullanılacak veri seti seçimi işlem yükünü çok ağırlaştırmayacak şekilde 2 boyuta indirgenmiş veri setlerinden oluşması, toplamda 6400 veriden oluştuğu için oldukça yeterli sayıda veri sunması ve ön işlenmiş verilerden oluşması gibi avantajlarıyla öne çıkan Kaggle Alzheimer veri setidir. Doğruluğu arttırmak için veri çoğaltma uygulanmıştır. Veri seti Google Drive ortamına yüklenerek ve Google Colab'a aktarımı sağlanmıştır. Kullanılacak Google Colab ortamındaki zaman ve işlem gücü kısıtları nedeniyle kısa zamanda verilerin yüksek doğrulukla eğitilmesi gerekmektedir. Bu nedenle TÖ yöntemi problem için uygun metot olarak belirlenmiştir. Derin Öğrenme için kullanılabilir açık kaynaklı Framework'ler vardır. Bu çalışmada Python yazılım dili ve TensorFlow Framework'ü yaygın kullanımı ve dokümana ulaşma kolaylığı ve iyi performansı göz önünde bulundurularak tercih edilmiştir. TensorFlow üzerinde çalışan Keras kütüphanesi başarımı yüksek modelleri kendi içinde kullanıma hazır olarak tanımlamakla birlikte bu modeller üzerinde işlemler yapma kolaylığını sağlamaktadır. Bu kütüphaneler yardımcı olarak verilerle işlem yapmayı kolaylaştıran Numpy, görüntüler üzerinde işlemler yapabilen OpenCV ve veri görselleştirme kütüphanesi Matplotlib kullanılmıştır.

3.1 Kullanılan Veri Seti

Bu veri seti seçilirken 3 boyutlu verilerle çalışmanın getireceği çok fazla işlem yükü göz önünde bulundurularak 2 boyutlu verilerden oluşan Kaggle Alzheimer veri seti kullanılmıştır. Bu veri seti kullanılacak modelin girişine uygun olacak şekilde yeniden boyutlandırılmıştır. Kullanılacak veri setinde verilerin %10'u test, %10'u doğrulama ve %80'i eğitim veri seti olarak ayrılmıştır. KAGGLE Alzheimer Veri Seti MRG tekniğiyle yapılan çekimlerin kesitlerinden oluşan 6400 veriden oluşmaktadır. Veri setinde 4 sınıf bulunmaktadır. Bu sınıflar Sağlıklı veya Bilişsel

Olarak Normal, Çok Hafif Bilişsel Bozukluk, Hafif Bilişsel Bozuklu ve Orta Bilişsel Bozukluktur. Veri Setine ait örnek görüntüler Tablo 3.1'de verilmiştir [25].

Tablo 3.1 Çalışmada kullanılan Kaggle veri setine ait sınıflar ve örnek resimleri gösteren tablo [25]

Bilişsel Olarak Normal	Çok Hafif Bilişsel Bozukluk	Hafif Bilişsel Bozukluk	Orta Bilişsel Bozukluk
			

Veri çoğaltma işlemi aşırı uydurma (overfitting) probleminden kaçınmak için uygulanan önemli bir adımdır. Medikal görüntüler gibi elde edilmesi bazı kısıtlar nedeniyle kolay olmadığı durumlarda daha da önem kazanmaktadır [53]. Yapılan çalışmada Keras kütüphanesi içinde bulunan ve veri çoğaltma için yazılmış ImageDataGenerator aracı kullanılarak veriler üzerinde geometrik dönüşümler uygulanmıştır. Veri seti üzerinde açısal döndürme, görüntü büyütme ve genişlik boyutunda kaydırma işlemleri uygulanarak veri sayısı artırılmıştır.

3.2 Kullanılan Donanım

Google Colaboratory (diğer adıyla Colab), Makine Öğrenimi eğitimini ve araştırmasını yaygınlaştırma amacına sahip bir projedir [54]. Colaboratory, TensorFlow, Matplotlib ve Keras gibi temel Makine Öğrenimi ve Yapay Zeka kütüphaneleriyle önceden yapılandırılmış Python 2 ve 3 versiyonlarıyla çalışma imkanı sağlamaktadır. Colaboratory' nin temel aldığı teknoloji Jupyter Notebook'dur. Jupyter, açık kaynaklı ve tarayıcı tabanlı bir araçtır. Jupyter Notebook yerel olarak veya bulutta çalışabilmektedir. Her dosya, her hücrenin komut dosyası dili veya işaretleme kodu içerdiği ve çıktının içine yerleştirildiği birden çok hücreden oluşmaktadır böylece hücre hücre işlem yaparak ara çıktıları

takip etme kolaylığından faydalanılabilmektedir [55]. Bir diğer avantajı büyük veri kümeleri doğrudan sunuculardan Google Drive'a çok yüksek hızda indirilebilir. Google Drive servisi Google Colab ile entegre çalıştırılabilir ve kimlik doğrulamasının ardından gerekli dosya Google Colab ortamına taşınabilir. Google Colab'in sağladığı bellek ve hesaplama miktarının kullanıcıya sunulacağı süre kısıtlıdır. Kullanıma açık versiyonu maksimum 12 saatlik işlemlere izin verirken Pro versiyonu maksimum 24 saatlik işleme izin vermektedir [56].

3.3 Kullanılan Yazılım

Çalışma yapılırken kullanılacak Framework, yazılım dili ve kütüphaneler çalışmanın başarımını hem dokümana ulaşma yönüyle hem de yazılımın optimize çalışması, kütüphanelerin birbirine entegre edilebilmesi ve yazılacak algoritmayı gerçekleştirecek araçlara sahip olması yönleriyle doğrudan etkileyecektir. Derin öğrenme için kullanılabilir Framework'ler Tablo 3.2'de sunulmuştur.

Tablo 3.2 Derin Öğrenme için kullanılabilir Framework'ler [39]

Framework	Lisans	Yazılım Dili	Arayüz Desteği	ESA Desteği	Derin İnanç Ağları Desteği
Caffe	BSD	C++	Python, MATLAB	Var	Yok
DL4j	Apache 2.0	Java	Java, Scala ,Python	Var	Var
Torch	BSD	C , Lua	C/C++, Lua, Python	Var	Var
Neon	Apache 2.0	Python	Python	Var	Var

Tablo 3.3 Derin Öğrenme için kullanılabilir Framework'ler [39] (devamı)

Theano	BSD	Python	Python	Var	Var
MXNet	Apache 2.0	C++	C++, Python, R, Scala, Pearl	Var	Var
CNTK	MIT	C++	Python, C++	Var	Yok
TensorFlow	Apache 2.0	C++, Python	Python, C/C++, Java	Var	Var

3.3.1.Python

Python, Guido van Rossum tarafından oluşturulan güçlü, yüksek seviyeli, nesne yönelimli bir programlama dilidir [57]. Yapılan uygulamada TensorFlow ile en optimum çalışan dil olması, çalışmada gerekli olan fonksiyonları bulunduran kütüphanelerin çokluğu, gerekli durumlarda kullanılacak yazılımların örnek şablonlarının fazla olması ve yazılımcı ekosisteminin büyük olmasının avantajıyla kolay bulunabilir olması nedenleri Python yazılım dilinin tercihinde etkili olmuştur.

3.3.2.Tensorflow

Başlangıçta Google'daki araştırmacılar tarafından oluşturulan TensorFlow, çok sayıda derin öğrenme kütüphanesi arasında en popüler olanıdır. TensorFlow veri akış grafiklerini kullanan sayısal hesaplamaları esnek ve ölçeklenebilir bir şekilde yapabilen yazılım kütüphanesidir. Bu kütüphane ve sunduğu araçlar, Makine Öğrenmesi modellerinin kullanıcılar tarafından sinir ağı ve diğer Makine Öğrenimi modellerini verimli bir şekilde programlayıp eğitmesine ve bunları üretmesine olanak tanır. TensorFlow' un temel algoritmaları, iyi derecede optimize edilmiş

C++ ve NVIDIA tarafından oluşturulan paralel bir hesaplama platformu ve API olan CUDA (Compute Unified Device Architecture) ile yazılmıştır. Python API diğerlerine kıyasla en eksiksiz ve kararlı olanıdır [58].

3.3.3 Keras

Keras, Python'da yazılmış ve Tensor Flow ile kullanılabilen ücretsiz, gelişmiş bir sinir ağı aracıdır. Bu araç bir Google geliştiricisi olan François Chollet tarafından tasarlanmıştır. Derin sinir ağlarında daha hızlı denemeler yapılmasına olanak sağlamak amacıyla kullanıcı dostu ve modüler olacak şekilde oluşturulmuştur. Keras, bir hata oluştuğunda geri bildirim vererek, sık kullanım durumlarının büyük çoğunluğu için kullanıcı etkinliklerinin miktarını azaltır. Öğrenmesi ve uygulaması basit olan, Son derece uyarlanabilir bir araçtır.

● Ağ modellerinin daha hızlı oluşturulması sayesinde kavranması ve birleştirilmesi kolaydır.

● Çoğu Yapay Zeka Framework'ü üzerinde çalışabilmektedir.

● Veri paralelliğine izin verir; bu, Keras'ın birden fazla GPU üzerinde aynı anda eğitilebileceği anlamına gelir.

● Bilgi paralelliğine izin verir; bu, Keras'ın aynı anda birden fazla GPU'da öğretilebileceği anlamına gelir, eğitim süresini kısaltır ve büyük miktarda veriyi yorumlayabilir [59].

3.3.4.OpenCV

OpenCV, Intel tarafından geliştirilen ve birçok görüntü işleme ve bilgisayarlı görme uygulaması için kullanılabilen bir Uygulama Çevre Birimi Arayüzü'dür (API). OpenCV projesi resmi olarak 1999 yılında başlatılmıştır ve proje başlangıçta gerçek zamanlı izleme gibi bir dizi projenin parçası olan bilgisayar işlemcisini yoğun bir şekilde kullanan uygulamaları geliştirmeye yönelik bir araştırmaydı.

Yapılan çalışmada bu kütüphanenin CV modülü kullanılmıştır. CV modülü görüntü üzerinde filtreler uygulama, geometrik dönüşümler yapma, renk uzayını değiştirme gibi işlemler yapılmasına olanak tanır. Morfoloji ve histogram işlemlerini desteklemektedir aynı zamanda yapısal analiz yapabilmektedir. Çalışmada

görüntülerin makine tarafından okunması ve giriş filtrelerine uygun olarak tekrardan boyutlandırılması bu kütüphane yardımıyla sağlanmıştır [60].

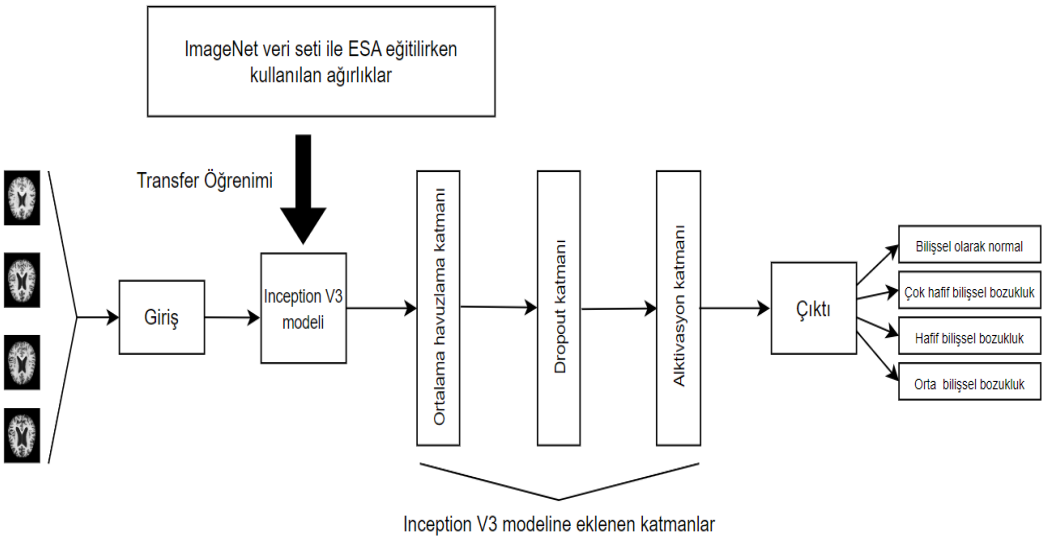
3.3.5.Numpy ve Matplotlib

NumPy, Python ile sayısal hesaplamayı mümkün kılan açık kaynaklı bir kütüphanedir. 2005 yılında Numeric ve Numarray kütüphanelerinin ilk çalışmaları temel alınarak oluşturulmuştur. NumPy' ın her zaman %100 açık kaynaklı bir yazılım olacağı ve herkesin kullanımına açık olacağı taahhüt edilmiştir [61]. Yapılan çalışmadaki dizi işlemleri için kullanılmıştır.

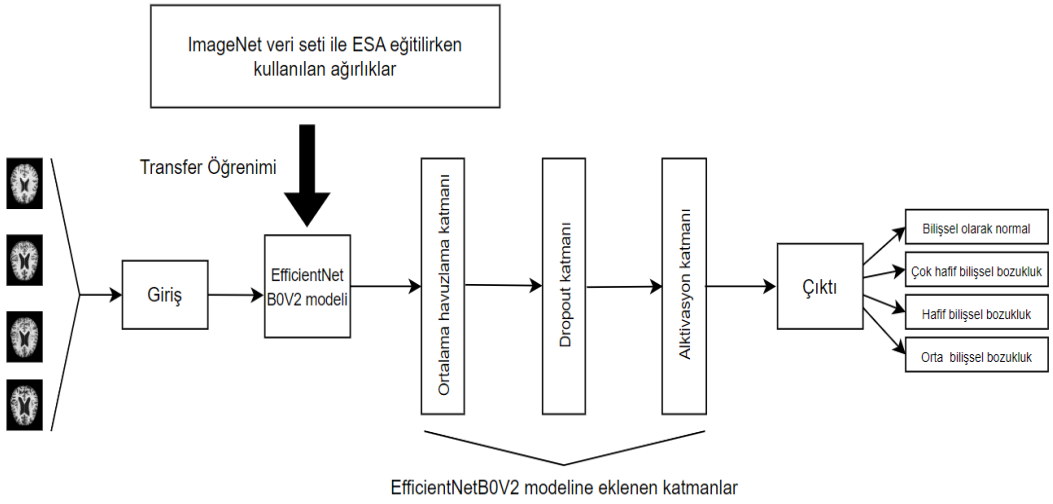
Matplotlib, Python'da statik, animasyonlu veya etkileşimli görselleştirmeler oluşturmaya yönelik kapsamlı bir kütüphanedir. Yüksek kalitede grafikler oluşturur. Yakınlaştırabilen kaydırabilen, güncelleyebilen etkileşimli şekiller oluşturabilir. Görsel stili ve düzeni özelleştirilebilir. Yapılan çalışmada önerilen ağların doğruluk grafiği Matplotlib kütüphanesi yardımıyla çizdirilmiştir [62].

3.4.Kullanılan Ağlar ve Önerilen yöntem

ImageNet, TensorFlow Framework'u ve keras kütüphanesi kullanılarak Inception V3 ve EfficientNet B0V2 ağları ImageNet ağırlıklarıyla eğitilecek ve katmanları üzerinde işlemler yapılabilecek şekilde yapılandırılmıştır. Bu ağın son katmanında Softmax sınıflandırıcı kullanılarak eğitim aşaması başlatılmıştır. 10 Epoch (Devir) kadar eğitim yapılmıştır. Inception V3 modeli için 7 saat 33 dakika eğitim süresi geçerken EfficientNet B0V2 için 1 saat 34 dakika sürede eğitim tamamlanmıştır. Eğitimin sonucunda doğruluk ve kayıp grafikleri çizdirilmiştir. Sınıflandırma raporu çıktı olarak alınmıştır. El ile hesaplanarak sağlaması yapılmıştır. Önerilen ağlar Şekil 3.1 ve Şekil 3.2'de verilmiştir.



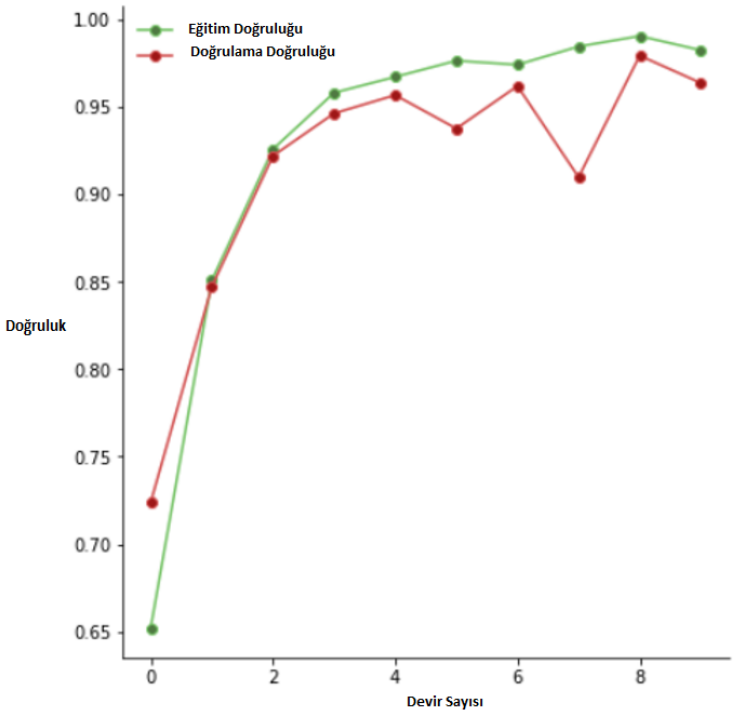
Şekil 3.1 Inception V3 modeli transfer öğrenimi gösterimi



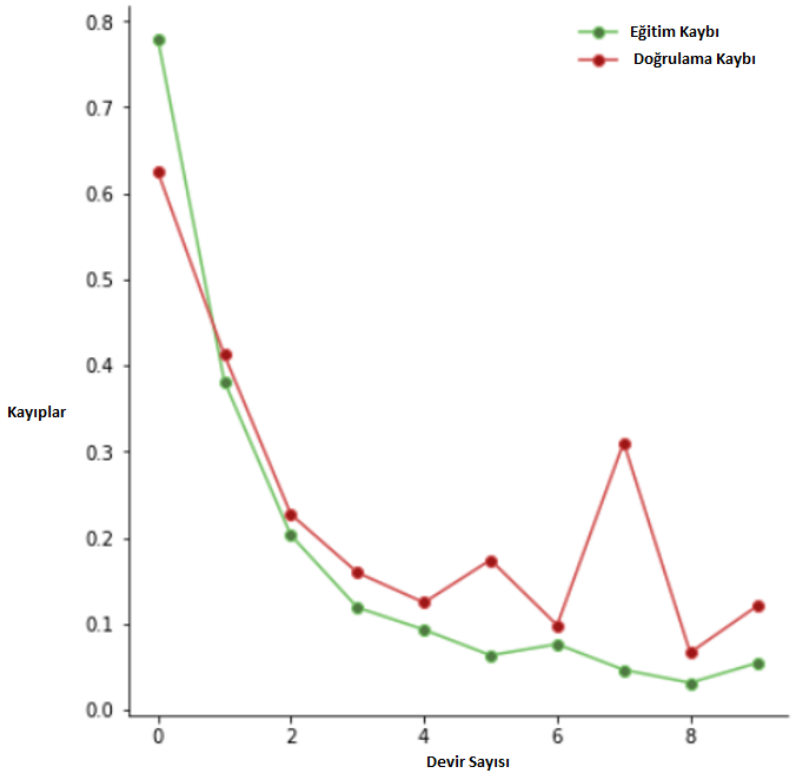
Şekil 3.2 EfficientNet B0V2 modeli transfer öğrenimi gösterimi

4
BULGULAR

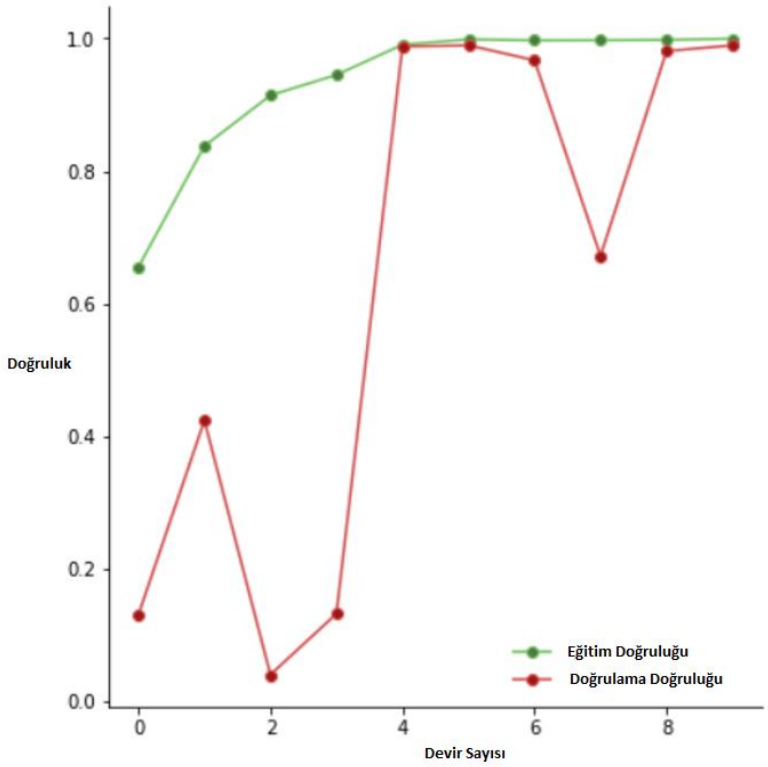
Bulgular bölümünde gerekli veri seti, yazılım gereçleri ve önerilen ağ ile yapılan eğitimin sonucu ve performans karşılaştırması yapılmıştır. Inception V3 modeli ImageNet ağırlıklarıyla eğitildiğinde genel doğruluk %99,96 ve doğrulama doğruluğu %98,96 bulunmuştur. Kayıplara bakılacak olursa genel kayıp 0,054 iken doğrulama kaybı 0,12 olarak bulunmuştur. Inception V3 modeli yerine EfficientNet B0V2 modeli kullanıldığında genel doğruluk %98,23 ve doğrulama doğruluğu %96,35 olarak bulunmuştur. Kayıp grafiğine bakılacak olursa 0,024 genel kayıp ve 0,031 doğrulama kaybına ulaşılmıştır. Sınıflandırıcı olarak Softmax sınıflandırıcı kullanılmıştır. Çalışma performansının analizi için karışıklık matrisi üzerinde her bir sınıf için Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) veriler belirlenmiştir. Karşılaştırılabilir başarımı göstermek için kesinlik, duyarlılık, F-1 skoru performans metrikleri hesaplanmıştır. EfficientNet B0V2 modeli için doğruluk grafiği Şekil 4.1'de ve kayıp grafiği Şekil 4.2'de, Inception V3 modeli için doğruluk grafiği şekil 4.3'de ve kayıp grafiği Şekil 4.4'de verilmiştir.



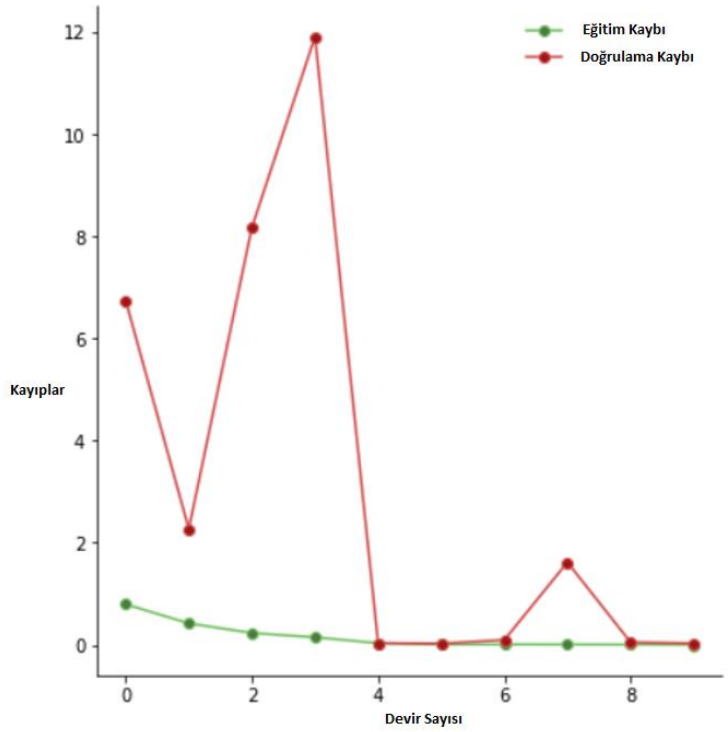
Şekil 4.1 EfficientNet B0V2 modeli için doğruluk grafiği [63]



Şekil 4.2 EfficientNet B0V2 modeli kayıp grafiği [63]



Şekil 4.3 Inception V3 modeli için doğruluk grafiği [63]



Şekil 4.4 Inception V3 modeli için kayıp grafiği [63]

Şekil 4.1 ve Şekil 4.3 gösteriyor ki yapılan çalışma çok az sayıda devir (Epoch) ile EfficientNet B0V2 ve Inception V3 modelleri için yapılan çalışmalarla kıyaslandığında oldukça yüksek bir doğruluğa ulaşılmıştır. Sınıf dağılımları tablo halinde sunulmuştur. Eğitim sonucunda her bir sınıf için DP, DN, YP ve YN veriler tablo üstünde gösterilerek performans çıktıları için yapılacak hesaplamalara uygun forma getirilmiştir. Her iki ağ için sınıf dağılımları aşağıdaki Tablo 4.1 ve Tablo 4.2'de gösterilmiştir.

Tablo 4.1 EfficientNet B0V2 modeli sınıf dağılımı [63]

Sınıflar	Sağlıklı	Çok Hafif	Hafif	Orta
Sağlıklı	317	2	0	0
Çok Hafif	16	202	2	0
Hafif	4	1	89	0
Orta	0	0	0	7

Tablo 4.2 Inception V3 modeli sınıf dağılımı [63]

Sınıflar	Sağlıklı	Çok Hafif	Hafif	Orta
Sağlıklı	318	1	0	0
Çok Hafif	3	217	0	0
Hafif	1	1	92	0
Orta	0	0	0	7

Tablo 4.1 ve Tablo 4.2' de sunulan verilerin hangi şekilde DP DN YP ve YN olarak ayrılacağı Tablo 4.3, Tablo 4.4, Tablo 4,5 ve Tablo 4.6'da verilmiştir. Bu ayrımın yapılması performans çıktılarının hesaplanması için gerekli bir adımdır. Yeşil kutucuk içinde gösterilen DP veriler veri setinde teşhis edilmeye çalışılan sınıfın doğru olarak sınıflandırıldığı durumu vermektedir. Gri renkli kutucukların içindeki YP veriler veri setinde teşhis edilmesi gereken sınıfın dışındaki verilerin sanki o sınıfa ait gibi sınıflandırılması nedeniyle oluşan ve mümkün olduğunca veri sayısı minimize edilmeye çalışılan bir veri grubudur. Mavi renkle boyalı kutucuklarda bulunan YN veriler teşhis edilmemesi gereken sınıftaki verileri sanki o sınıfta gibi algılanması ile oluşan ve veri sayısının çok az veya hiç olmaması istenen bir gruptur. Kırmızı boyalı kutucuklarla gösterilen DN veriler veri setinde teşhis edilmemesi gereken sınıfların teşhis edilmemesi durumudur.

Tablo 4.3 Sağlıklı sınıfına göre karışıklık matrisi dağılımı

SINIFLAR	Sağlıklı	Çok Hafif	Hafif	Orta
Sağlıklı	DP	YN	YN	YN
Çok Hafif	YP	DN	DN	DN
Hafif	YP	DN	DN	DN
Orta	YP	DN	DN	DN

Tablo 4.4 Çok Hafif sınıfına göre karışıklık matrisi dağılımı

SINIFLAR	Sağlıklı	Çok Hafif	Hafif	Orta
Sağlıklı	DN	YP	DN	DN
Çok Hafif	YN	DP	YN	YN
Hafif	DN	YP	DN	DN
Orta	DN	YP	DN	DN

Tablo 4.5 Hafif sınıfına göre karışıklık matrisi dağılımı

SINIFLAR	Sağlıklı	Çok Hafif	Hafif	Orta
Sağlıkı	DN	DN	YP	DN
Çok Hafif	DN	DN	YP	DN
Hafif	YN	YN	DP	YN
Orta	DN	DN	YP	DN

Tablo 4.6 Orta sınıfına göre karışıklık matrisi dağılımı

SINIFLAR	Sağlıklı	Çok Hafif	Hafif	Orta
Sağlıklı	DN	DN	DN	YP
Çok Hafif	DN	DN	DN	YP
Hafif	DN	DN	DN	YP
Orta	YN	YN	YN	DP

Aşağıda verilen Denklem 4.1 Denklem 4.2 ve Denklem 4.3'de gruplara ayrılan veriler yerine yazılırsa performans metrikleri elde edilmiş olacaktır. Bu

hesaplamalar hem Inception V3 hem de EfficientNet B0V2 modeli için yapılarak Tablo 4.7 ve Tablo 4.8'de sunulmuştur.

Kesinlik: DP ve YP verilerin yani pozitif verilerin kaçının doğru olarak pozitif tahmin edildiğini veren kavramdır [64].

$$K = \frac{DP}{DP+YP} \quad \textbf{(Denklem 4.1)}$$

Duyarlılık: DP olarak sınıflandırılması gereken verilerin gerçekte ne kadarının DP olarak sınıflandırıldığını veren kavramdır. YN veriler bu performans ölçütünün yüksekliğini etkiler [64].

$$D = \frac{DP}{DP+YN} \quad \textbf{(Denklem 4.2)}$$

F-1 Skoru: Duyarlılık ve Kesinlik arasında harmonik bir ortalamayı temsil eder [65].

$$F1 = 2 * \frac{Kesinlik*Duyarlılık}{Kesinlik+Duyarlılık} \quad \textbf{(Denklem 4.3)}$$

Tablo 4.7'de EfficientNetB0V2 modeli için kesinlik duyarlılık ve F-1 Skoru çıktıları verilmiştir.

Tablo 4.7 EfficientNet B0V2 modeli performans çıktıları [63]

	Kesinlik	Duyarlılık	F-1 Skoru
Sağlıklı	%94,06	%99,37	%96,64
Çok Hafif	%98,53	%91,81	%95,05
Hafif	%97,80	%94,68	%96,21
Orta Seviye	%100	%100	%100

Tablo 4.8'de Inception V3 modeli için kesinlik duyarlılık ve F-1 Skoru çıktıları verilmiştir.

Tablo 4.8 Inception V3 modeli performans çıktıları [63]

	Kesinlik	Duyarlılık	F-1 Skoru
Sağlıklı	%98,75	%99,68	%99,21
Çok Hafif	%99,68	%98,63	%98,85
Hafif	%100	%97,87	%98,92
Orta Seviye	%100	%100	%100

5
SONUÇ

Yapay Zeka ve uygulamaları günümüzde kendine git gide daha fazla yer bulan ve insan gücüne olan ihtiyacı azaltan araçlardandır. Sağlık alanında da buna benzer teşhise yardımcı ve hekimlerin iş yükünü azaltablecek nitelikteki çalışmaların kullanımı gün geçtikçe artmaktadır. Bu çalışmalarda uzun süren işlemlerin çok daha kısa zamanda yapılması ve teşhis konusunda tıbbi alanda kullanılabilir nitelikte doğru sonuçlar vermesi hedeflenmektedir. Yapılmış olan çalışmada açık erişim Kaggle veri seti sınıflandırma için kullanılmıştır. Veri seti oluşturulurken hasta birey sayısının sağlıklı birey sayısına göre çok az sayıda olması veri setinin küçük olmasına yol açmakta, çok fazla veri alınsa bile sınıflar arasında veri sayılarında dengesizlik oluşturmaktadır. Diğer bir zorluk verilerin etiketlenmesi için alanında uzman kişilere ihtiyaç olmasıdır. Bu nedenle mevcut açık veri setleri ya çok büyütülememiş ya da çok sayıda veri olsa bile sınıflardaki veri sayıları dengesiz dağılmıştır. Çok daha fazla veriden oluşan ve sınıflar arasındaki veri sayısı dengeli olan bir veri setinin oluşturulması daha farklı tekniklerle aşırı uydurma olmadan problemin incelenebilmesine olanak verecektir.

Yapılan çalışmada erişime açık veri setleriyle ve çeşitli yöntemlerle AH sınıflandırması yapılmıştır. Literatürdeki çalışmalarla karşılaştırıldığında kabul görecek düzeyde doğruluğa ulaşılmıştır. Bu çalışmanın sonucunda TÖ yöntemiyle Google Colab ortamında Google Drive'da tutulan veri seti kullanılarak eğitim yapılmıştır. Böylece bilgisayar donanımının minimum kullanımıyla 2 boyutlu verilerle yüksek doğruluklu sınıflandırma yapılabileceği gösterilmiştir. Sunulan sonuçlar ve karışıklık matrisiyle birlikte çalışmanın dengesiz sayılabilecek bir veri seti kullanılsa bile sınıf dağılımının yüksek başarıyla yapıldığı gösterilmiştir.

Bundan sonraki çalışmalarda veri setine dahil olmayan bir görüntünün arayüz yardımıyla ön işlemleri yapılıp veri setiyle aynı formata getirilerek eğitilen model tarafından hangi sınıfa dahil olacağının tahmin edilebileceği, ya da MR cihazından direkt olarak bulut yardımıyla işlenmeye gönderilen görüntüyle birlikte hızlı bir tahmin sonucu elde edilebileceği düşünülmektedir. Gelecekte bu hastalığın tedavisine harcanan bütçe hasta saysının artmasına paralel olarak artacaktır. Bu tür

çalışmaların medikal cihazlara yüksek doğrulukla teşhis yapacak şekilde dahil edilmesi hem hastalığın ilerlemesini engelleyici önlemler almaya ve böylece hastaların yavaşlatıcı tedbirlerle kısmen daha konforlu bir hayat sürmelerine, hem hekimlere zaman kazandıracak faydalı bir araç olmaya hem de tedavi için harcanacak bütçeyi düşürecek bir çözüm sunmaya aday olacaktır.

KAYNAKÇA

[1] M. S. Henry, A. P. Passmore, S. Todd, B. McGuinness, D. Craig, ve J. A. Johnston, "The development of effective biomarkers for Alzheimer's disease: a review", *Int. J. Geriatr. Psychiatry*, c. 28, sy 4, ss. 331-340, 2013, doi: 10.1002/gps.3829.

[2] C. Lynch, "World Alzheimer Report 2019: Attitudes to dementia, a global survey", *Alzheimers Dement.*, c. 16, sy S10, s. e038255, 2020, doi: 10.1002/alz.038255.

[3] A. D. International ve C. Patterson, "World Alzheimer Report 2018: The state of the art of dementia research: New frontiers", Eyl. 2018, Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://www.alzint.org/resource/world-alzheimer-report-2018/

[4] C. Saraiva, C. Praça, R. Ferreira, T. Santos, L. Ferreira, ve L. Bernardino, "Nanoparticle-mediated brain drug delivery: Overcoming blood–brain barrier to treat neurodegenerative diseases", *J. Controlled Release*, c. 235, ss. 34-47, Ağu. 2016, doi: 10.1016/j.jconrel.2016.05.044.

[5] Ü. D. Özkay, Y. Öztürk, ve Ö. Can, "YAŞLANAN DÜNYANIN HASTALIĞI: ALZHEİMER HASTALIĞI", *SDÜ Tıp Fakültesi Derg.*, c. 18, sy 1, Art. sy 1, Mar. 2011, doi: 10.17343/sdutfd.55108.

[6] L. Houria, N. Belkhamsa, A. Cherfa, ve Y. Cherfa, "Multi-modality MRI for Alzheimer's disease detection using deep learning", *Phys. Eng. Sci. Med.*, c. 45, sy 4, ss. 1043-1053, Ara. 2022, doi: 10.1007/s13246-022-01165-9.

[7] C. Techa, M. Ridouani, L. Hassouni, ve H. Anoun, "Alzheimer's Disease Multi-class Classification Model Based on CNN and StackNet Using Brain MRI Data", içinde *Proceedings of the 8th International Conference on Advanced Intelligent Systems and Informatics 2022*, A. E. Hassanien, V. Snášel, M. Tang, T.-W. Sung, ve K.-C. Chang, Ed., içinde Lecture Notes on Data Engineering and Communications Technologies. Cham: Springer

International Publishing, 2023, ss. 248-259. doi: 10.1007/978-3-031-20601-6_23.

[8] M. Menagadevi, S. Mangai, N. Madian, ve D. Thiyagarajan, "Automated prediction system for Alzheimer detection based on deep residual autoencoder and support vector machine", *Optik*, c. 272, s. 170212, Şub. 2023, doi: 10.1016/j.ijleo.2022.170212.

[9] P. S. Sisodia, G. K. Ameta, Y. Kumar, ve N. Chaplot, "A Review of Deep Transfer Learning Approaches for Class-Wise Prediction of Alzheimer's Disease Using MRI Images", *Arch. Comput. Methods Eng.*, c. 30, sy 4, ss. 2409-2429, May. 2023, doi: 10.1007/s11831-022-09870-0.

[10] H. A. Helaly, M. Badawy, ve A. Y. Haikal, "Deep Learning Approach for Early Detection of Alzheimer's Disease", *Cogn. Comput.*, c. 14, sy 5, ss. 1711-1727, Eyl. 2022, doi: 10.1007/s12559-021-09946-2.

[11] H. Acharya, R. Mehta, ve D. Kumar Singh, "Alzheimer Disease Classification Using Transfer Learning", içinde *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, Nis. 2021, ss. 1503-1508. doi: 10.1109/ICCMC51019.2021.9418294.

[12] A. Mehmood, M. Maqsood, M. Bashir, ve Y. Shuyuan, "A Deep Siamese Convolution Neural Network for Multi-Class Classification of Alzheimer Disease", *Brain Sci.*, c. 10, sy 2, Art. sy 2, Şub. 2020, doi: 10.3390/brainsci10020084.

[13] M. Ü. Öziç ve S. Özşen, "3B Alzheimer MR Görüntülerinin Hacimsel Kayıp Bölgelerindeki Voksel Değerleri Kullanılarak Sınıflandırılması", *El-Cezeri*, c. 7, sy 3, Art. sy 3, Eyl. 2020, doi: 10.31202/ecjse.728049.

[14] M. Liu *vd.*, "A multi-model deep convolutional neural network for automatic hippocampus segmentation and classification in Alzheimer's disease", *NeuroImage*, c. 208, s. 116459, Mar. 2020, doi: 10.1016/j.neuroimage.2019.116459.

[15] M. EL-Geneedy, H. E.-D. Moustafa, F. Khalifa, H. Khater, ve E. AbdElhalim, "An MRI-based deep learning approach for accurate detection

of Alzheimer's disease", *Alex. Eng. J.*, c. 63, ss. 211-221, Oca. 2023, doi: 10.1016/j.aej.2022.07.062.

[16] S. Murugan *vd.*, "DEMNET: A Deep Learning Model for Early Diagnosis of Alzheimer Diseases and Dementia From MR Images", *IEEE Access*, c. 9, ss. 90319-90329, 2021, doi: 10.1109/ACCESS.2021.3090474.

[17] M. Yildirim ve A. Çinar, "Classification of Alzheimer's Disease MRI Images with CNN Based Hybrid Method", *Ingénierie Systèmes Inf.*, c. 25, ss. 413-418, Eyl. 2020, doi: 10.18280/isi.250402.

[18] A. Chandy, "A REVIEW ON IOT BASED MEDICAL IMAGING TECHNOLOGY FOR HEALTHCARE APPLICATIONS", *J. Innov. Image Process.*, c. 1, sy 01, ss. 51-60, Eki. 2019, doi: 10.36548/jiip.2019.1.006.

[19] F. Atlan ve İ. Pençe, "Yapay Zekâ ve Tıbbi Görüntüleme Teknolojilerine Genel Bakış", *Acta Infologica*, c. 5, sy 1, Art. sy 1, Haz. 2021.

[20] N. Nawreen, U. Hany, ve T. Islam, "Lung Cancer Detection and Classification using CT Scan Image Processing", içinde *2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI)*, Tem. 2021, ss. 1-6. doi: 10.1109/ACMI53878.2021.9528297.

[21] R. K. Kumrular ve A. Polat, "Klinik Uygulamalarda İleri Biyomedikal Görüntüleme Teknolojileri", *Avrupa Bilim Ve Teknol. Derg.*, sy 23, Art. sy 23, Nis. 2021, doi: 10.31590/ejosat.840321.

[22] H. Kasban, M. A. M. El-Bendary, ve D. H. Salama, "A Comparative Study of Medical Imaging Techniques", 2015.

[23] V. I. Mikla ve V. V. Mikla, *Medical Imaging Technology*. Elsevier, 2013.

[24] W. M. van Oostveen ve E. C. M. de Lange, "Imaging Techniques in Alzheimer's Disease: A Review of Applications in Early Diagnosis and Longitudinal Monitoring", *Int. J. Mol. Sci.*, c. 22, sy 4, Art. sy 4, Oca. 2021, doi: 10.3390/ijms22042110.

[25] "Alzheimer's Dataset (4 class of Images)". Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images

[26] M. G. van der Vaart, R. Meerwaldt, R. H. J. A. Slart, G. M. van Dam, R. A. Tio, ve C. J. Zeebregts, "Application of PET/SPECT Imaging in Vascular Disease", *Eur. J. Vasc. Endovasc. Surg.*, c. 35, sy 5, ss. 507-513, May. 2008, doi: 10.1016/j.ejvs.2007.11.016.

[27] C. Janiesch, P. Zschech, ve K. Heinrich, "Machine learning and deep learning", *Electron. Mark.*, c. 31, sy 3, ss. 685-695, Eyl. 2021, doi: 10.1007/s12525-021-00475-2.

[28] N. Sharma, R. Sharma, ve N. Jindal, "Machine Learning and Deep Learning Applications-A Vision", *Glob. Transit. Proc.*, c. 2, sy 1, ss. 24-28, Haz. 2021, doi: 10.1016/j.gltp.2021.01.004.

[29] B. Mahesh, *Machine Learning Algorithms -A Review*. 2019. doi: 10.21275/ART20203995.

[30] J. Latif, C. Xiao, A. Imran, ve S. Tu, "Medical Imaging using Machine Learning and Deep Learning Algorithms: A Review", içinde *2019 2nd International Conference on Computing, Mathematics and Engineering*

[31] W. S. McCulloch ve W. Pitts, "A logical calculus of the ideas immanent in nervous activity", *Bull. Math. Biophys.*, c. 5, sy 4, ss. 115-133, Ara. 1943, doi: 10.1007/BF02478259.

[32] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain", *Psychol. Rev.*, c. 65, sy 6, ss. 386-408, 1958, doi: 10.1037/h0042519.

[33] M. Minsky ve S. A. Papert, *Perceptrons: An Introduction to Computational Geometry*. The MIT Press, 2017. doi: 10.7551/mitpress/11301.001.0001.

[34] D. H. Ackley, G. E. Hinton, ve T. J. Sejnowski, "A learning algorithm for boltzmann machines", *Cogn. Sci.*, c. 9, sy 1, ss. 147-169, Oca. 1985, doi: 10.1016/S0364-0213(85)80012-4.

[35] K. Fukushima, "Neocognitron: A hierarchical neural network capable of visual pattern recognition", *Neural Netw.*, c. 1, sy 2, ss. 119-130, Oca. 1988, doi: 10.1016/0893-6080(88)90014-7.

[36] Y. Lecun, L. Bottou, Y. Bengio, ve P. Haffner, "Gradient-based learning applied to document recognition", *Proc. IEEE*, c. 86, sy 11, ss. 2278-2324, Kas. 1998, doi: 10.1109/5.726791.

[37] G. E. Hinton, S. Osindero, ve Y.-W. Teh, "A Fast Learning Algorithm for Deep Belief Nets", *Neural Comput.*, c. 18, sy 7, ss. 1527-1554, Tem. 2006, doi: 10.1162/neco.2006.18.7.1527.

[38] "Reducing the Dimensionality of Data with Neural Networks | Science". Erişim: 15 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://www.science.org/doi/abs/10.1126/science.1127647

[39] S. Pouyanfar *vd.*, "A Survey on Deep Learning: Algorithms, Techniques, and Applications", *ACM Comput. Surv.*, c. 51, sy 5, s. 92:1-92:36, Eylül 2018, doi: 10.1145/3234150.

[40] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, ve M. S. Lew, "Deep learning for visual understanding: A review", *Neurocomputing*, c. 187, ss. 27-48, Nis. 2016, doi: 10.1016/j.neucom.2015.09.116.

[41] A. Voulodimos, N. Doulamis, A. Doulamis, ve E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review", *Comput. Intell. Neurosci.*, c. 2018, s. e7068349, Şub. 2018, doi: 10.1155/2018/7068349.

[42] A. Şeker, B. Diri, ve H. H. Balık, "Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme", *Gazi Mühendis. Bilim. Derg.*, c. 3, sy 3, Art. sy 3, Ara. 2017.

[43] A. Demir, F. Yilmaz, ve O. Kose, "Early detection of skin cancer using deep learning architectures: resnet-101 and inception-v3", içinde *2019 Medical Technologies Congress (TIPTEKNO)*, Eki. 2019, ss. 1-4. doi: 10.1109/TIPTEKNO47231.2019.8972045.

[44] L. Deng, H. Suo, ve D. Li, "Deepfake Video Detection Based on EfficientNet-V2 Network", *Comput. Intell. Neurosci.*, c. 2022, s. e3441549, Nis. 2022, doi: 10.1155/2022/3441549.

[45] M. Tan ve Q. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", içinde *Proceedings of the 36th International Conference on Machine Learning*, PMLR, May. 2019, ss.

6105-6114. Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://proceedings.mlr.press/v97/tan19a.html

[46] "Fig. 2. Architecture of EfficientNet-B0 with MBConv as Basic building...", ResearchGate. Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://www.researchgate.net/figure/Architecture-of-EfficientNet-B0-with-MBConv-as-Basic-building-blocks_fig4_344410350

[47] H. Polat, "Senkrosıkıştırma dönüşümü ve derin transfer öğrenimi ile Alzheimer hastalığının EEG tabanlı otomatik tespiti", *Dicle Üniversitesi Mühendis. Fakültesi Mühendis. Derg.*, c. 14, sy 1, Art. sy 1, Mar. 2023, doi: 10.24012/dumf.1246052.

[48] K. Firildak, M. F. Talu, ve G. Çelik, "Transfer Öğrenme ve Çekişmeli Üretici Ağ Yaklaşımlarını Kullanarak Cilt Lezyonu Sınıflandırma Doğruluğunu İyileştirilmesi", *Fırat Üniversitesi Mühendis. Bilim. Derg.*, c. 32, sy 2, Art. sy 2, Eyl. 2020, doi: 10.35234/fumbd.629984.

[49] H. Polat ve M. S. Özerdem, "Derin Transfer Öğrenimi Yaklaşımı ile Kamusal Alanda Medikal Maske Kullanımının Otomatik Kontrolü", *Türk Doğa Ve Fen Derg.*, c. 10, sy 2, Art. sy 2, Ara. 2021, doi: 10.46810/tdfd.948098.

[50] "Sensors | Free Full-Text | Incorporating a Novel Dual Transfer Learning Approach for Medical Images". Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://www.mdpi.com/1424-8220/23/2/570

[51] P. J. LaMontagne *vd.*, "OASIS-3: Longitudinal Neuroimaging, Clinical, and Cognitive Dataset for Normal Aging and Alzheimer Disease", Radiology and Imaging, preprint, Ara. 2019. doi: 10.1101/2019.12.13.19014902.

[52] "ADNI | Alzheimer's Disease Neuroimaging Initiative". Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://adni.loni.usc.edu/

[53] C. Shorten ve T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning", *J. Big Data*, c. 6, sy 1, s. 60, Ara. 2019, doi: 10.1186/s40537-019-0197-0.

[54] "Colaboratory'ye Hoş Geldiniz - Colaboratory". Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://colab.research.google.com/

[55] T. Carneiro, R. V. Medeiros Da NóBrega, T. Nepomuceno, G.-B. Bian, V. H. C. De Albuquerque, ve P. P. R. Filho, "Performance Analysis of Google Colaboratory as a Tool for Accelerating Deep Learning Applications", *IEEE Access*, c. 6, ss. 61677-61685, 2018, doi: 10.1109/ACCESS.2018.2874767.

[56] P. Kanani, "Deep Learning to Detect Skin Cancer using Google Colab", *Int. J. Eng. Adv. Technol.*, c. 8, ss. 2176-2183, Ağu. 2019, doi: 10.35940/ijeat.F8587.088619.

[57] K. R. Srinath, "Python – The Fastest Growing Programming Language", c. 04, sy 12.

[58] B. Pang, E. Nijkamp, ve Y. N. Wu, "Deep Learning With TensorFlow: A Review", *J. Educ. Behav. Stat.*, c. 45, sy 2, ss. 227-248, Nis. 2020, doi: 10.3102/1076998619872761.

[59] D. S. Ahmed, R. shaker ibrahim Al-badri, F. A. Hashim, ve N. M. Hussien, "KERAS DEEP LEARNING PACKAGE IN PYTHON: A REVIEW", *Eur. J. Interdiscip. Res. Dev.*, c. 19, ss. 24-29, Eyl. 2023.

[60] M. Mohamad, *A Review on OpenCV*. 2015. doi: 10.13140/RG.2.1.2269.8721.

[61] "NumPy - About Us". Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://numpy.org/about/

[62] "Matplotlib — Visualization with Python". Erişim: 14 Kasım 2023. [Çevrimiçi]. Erişim adresi: https://matplotlib.org/

[63] H. E. Elp, B. Bolat "Alzheimer Hastalığının Transfer Öğrenimi Yöntemiyle Teşhisi," International Researches Congress on Natural and Engineering Sciences, Online, 2023, ss. 123-133

[64] E. Efeoğlu, "Kablosuz Sinyal Gücünü Kullanarak İç Mekan Kullanıcı Lokalizasyonu için Karar Ağacı Algoritmalarının Karşılaştırılması", *Acta Infologica*, c. 6, sy 2, Art. sy 2, Ara. 2022, doi: 10.26650/acin.1076352.

[65] Y. Liu, Y. Zhou, S. Wen, ve C. Tang, "A Strategy on Selecting Performance Metrics for Classifier Evaluation", *Int. J. Mob. Comput. Multimed.*

Commun. IJMCMC, c. 6, sy 4, ss. 20-35, Eki. 2014, doi: 10.4018/IJMCMC.2014100102.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirisi

1. H. E. Elp, B. Bolat "Alzheimer Hastalığının Transfer Öğrenimi Yöntemiyle Teşhisi," International Researches Congress on Natural and Engineering Sciences, Online, 2023, ss. 123-133