T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

# YÜKSEK LİSANS TEZİ

# ALZHEİMER TANISI İÇİN DERİN ÖĞRENME TABANLI ANALİZ

**Ravza Begüm ATAK**

**DANIŞMAN**
**Doç. Dr. Muhammed Ali AYDIN**

**II. DANIŞMAN**
**Dr. Öğr. Üyesi Muhammed Erdem İSENKUL**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı**

**Ağustos, 2024**

Bu yüksek lisans tezimi hiçbir zaman desteğini esirgemeyen aileme ithaf ediyorum…

# BÜTÇE DESTEKLERİ

## ALZHEİMER TANISI İÇİN DERİN ÖĞRENME TABANLI ANALİZ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

# TEŞEKKÜR

Araştırmamın her aşamasında bana yardımcı olan değerli tez danışmanım Doç. Dr. Muhammed Ali Aydın'a, bu çalışmanın yürütülmesi sırasında desteğini esirgemeyen ikinci danışmanım Dr. Öğr. Üyesi Muhammed Erdem İsenkul'a, desteği ve her zaman yanımda olduğu için sevgili eşime, çalışmalarım sırasında gösterdiği sabır için sevgili kızıma, benim bu günlere gelmem için hiçbir fedakârlıktan kaçınmayan ve her zaman yanımda olan sevgili aileme sonsuz teşekkür ederim.

Ağustos 2024 Ravza Begüm ATAK

# İÇİNDEKİLER

**Sayfa No**

**BÜTÇE DESTEKLERİ** ..... **iii**
**TEŞEKKÜR** ..... **iiv**
**İÇİNDEKİLER** ..... **v**
**ŞEKİL LİSTESİ** ..... **viii**
**TABLO LİSTESİ** ..... **viiix**
**SİMGE VE KISALTMA LİSTESİ** ..... **x**
**ÖZET** ..... **xii**
**ABSTRACT** ..... **xiiiv**
**1. GİRİŞ** ..... **1**
**2. KAVRAMSAL ÇERÇEVE** ..... **3**
2.1. ALZHEİMER HASTALIĞI ..... 3
2.1.1. Alzheimer Hastalığı Semptomları ..... 4
2.1.2. Alzheimer Hastalığı Tanı Teknikleri ..... 4
2.1.3. Alzheimer Hastalığı Tanısında Güncel Durum ve Zorluklar ..... 5
2.1.4. Alzheimer Hastalığı Teşhisinde Kullanılan Görüntüleme Teknikleri ..... 6
*2.1.4.1. Bilgisayarlı Tomografi* ..... 6
*2.1.4.2. Pozitron Emisyon Tomografisi* ..... 7
*2.1.4.3. Manyetik Rezonans Görüntüleme* ..... 7
2.1.5. Literatürde Yapılan Çalışmalar ..... 9
**3. YÖNTEM** ..... **13**
3.1. DERİN ÖĞRENME ..... 13
3.1.1. Evrişimsel Sinir Ağları ..... 13
*3.1.1.1. Evrişim Katmanı* ..... 14
*3.1.1.2. Havuzlama Katmanı* ..... 15
*3.1.1.3. Tam Bağlı Katman* ..... 16
*3.1.1.4 Giriş ve Çıkış Katmanı* ..... 17
*3.1.1.5. Dropout Katmanı* ..... 19

3.1.2. Evrişimsel Sinir Ağı Mimarilerinde Kullanılan Blok Yapıları ..... 19
*3.1.2.1. Kaybolan Gradyan Problemi* ..... 20
*3.1.2.2. Eklemeli Bağlantı: Artık Bağlantı Modeli* ..... 20
*3.1.2.3 Birleştirmeli Bağlantı: Dense Blok Modeli* ..... 20
*3.1.2.4. Inception Mimarisi* ..... 21
*3.1.2.5. AlexNet Mimarisi* ..... 22
*3.1.2.6. VGG16 Mimarisi* ..... 23
*3.1.2.7. VGG19 Mimarisi* ..... 24
*3.1.2.8. Xception Mimarisi* ..... 24
*3.1.2.9. ResNet Mimarisi* ..... 25
*3.1.2.10 Transfer Öğrenme* ..... 26
3.1.3. Performans Metrikleri ..... 27
**4. BULGULAR ..... 29**
4.1. VERİ KÜMESİ VE ÖN İŞLEME ..... 34
4.1.1. Veri Kümesi Eldesi ..... 34
4.2. KULLANILAN YÖNTEM VE MİMARİLER ..... 37
4.2.1. Birinci Model: Özgün Mimari ..... 38
4.2.2. İkinci Model: Xception ..... 40
4.2.3. Üçüncü Model: Xception + Sınıflandırıcı ..... 41
4.2.4. Dördüncü Model: VGG16 ..... 43
4.2.5. Beşinci Model: VGG16 + Sınıflandırıcı ..... 44
4.2.6. Altıncı Model: VGG19 ..... 45
4.2.7. Yedinci Model: VGG19 +Sınıflandırıcı ..... 46
4.3. SONUÇLAR VE TARTIŞMA ..... 47
4.3.1. Deneysel Ayarlar ..... 47
4.3.2. Hiperparametre Ayarları ve Optimizasyon ..... 47
**5. TARTIŞMA ..... 49**
5.1. DEĞERLENDİRME METRİKLERİ ..... 54
5.2. MODELLERİN SINIFLANDIRMA SONUÇLARI ..... 56
5.3. GÜÇLÜ YÖNLER VE SINIRLAMALAR ..... 60
**6. SONUÇ VE ÖNERİLER ..... 63**
**KAYNAKLAR ..... 65**
**İNTİHAL RAPORU İLK SAYFASI ..... 80**

# ŞEKİL LİSTESİ

**Sayfa No**

**Şekil 2.1:** Üç farklı kategoriye ait beyin MR görüntüleri ..... 8
**Şekil 3.1:** Evrişim katmanı. ..... 15
**Şekil 3.2:** Maksimim ve ortalama havuzlama işlemi ..... 16
**Şekil 3.3:** Dropout işlemi. ..... 19
**Şekil 3.4:** AlexNet Mimarisi ..... 22
**Şekil 3.5:** VGG19 mimarisi ..... 23
**Şekil 3.6:** VGG19 mimarisi ..... 24
**Şekil 3.7:** Xception mimarisi ..... 25
**Şekil 4.1:** AH erken tanısı iş akış grafiği ..... 33
**Şekil 4.2:** Veri kümesine ait örnek görüntü kareleri ..... 36
**Şekil 4.3:** Veri artırımı işlemleri a) Orijinal görüntü, b) Döndürme, c) Genişlik kaydırma, d) Yükseklik kaydırma e) Yatay çevirme, f) Dolgu ..... 37
**Şekil 4.4:** Birinci mimarimizin ağ blok tasarımı ..... 40
**Şekil 4.5:** İkinci mimarimizin ağ blok tasarımı ..... 41
**Şekil 4.6:** Üçüncü mimarimizin ağ blok tasarımı ..... 43
**Şekil 4.7:** Dördüncü mimarimizin ağ blok tasarımı ..... 44
**Şekil 4.8:** Beşinci mimarimizin ağ blok tasarımı ..... 45
**Şekil 4.9:** Altıncı mimarimizin ağ blok tasarımı ..... 46
**Şekil 4.10:** Yedinci mimarimizin ağ blok tasarımı ..... 46
**Şekil 5.1:** Birinci modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 50
**Şekil 5.2:** İkinci modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 50
**Şekil 5.3:** Üçüncü modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 51
**Şekil 5.4:** Dördüncü modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 51
**Şekil 5.5:** Beşinci modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 52
**Şekil 5.6:** Altıncı modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 52
**Şekil 5.7:** Yedinci, modelimizin eğitim ve kayıp fonksiyon grafikleri ..... 53
**Şekil 5.8:** Modellerin test veri seti karışıklık matrisleri ..... 58
**Şekil 5.9:** Modellerin test veri seti ROC eğrileri ..... 60

# TABLO LİSTESİ

**Sayfa No**

**Tablo 4.1:** OASIS-1 veri tabanı ait demografik özellikler ..... 35
**Tablo 4.2:** Model eğitim/test için kullanılan veri dağılımı ..... 36
**Tablo 4.3:** Birinci mimarimiz ..... 39
**Tablo 4.4:** Xception modeli mimarisi ..... 41
**Tablo 4.5:** İkinci mimarimizin ağ blok tasarımı ..... 42
**Tablo 4.6:** Modellerde kullanılan hiper parametreler ..... 48
**Tablo 5.1:** Modellerin performans sonuçları ..... 55

# SİMGE VE KISALTMA LİSTESİ

**Simgeler** **Açıklama**

$y$ : Blok çıkışı
$\alpha$ : Öğrenme oranı
$\sum$ : Toplam fonksiyonu
$e$ : Eular sayısı
$z_i$ : Bir sınıfa ait girdi değeri
$x'$ : Normalize edilmiş değer
$\sigma$ : Standart sapma

**Kısaltmalar** **Açıklama**

**2B** : İki Boyutlu
**3B** : Üç Boyutlu
**AH** : Alzheimer Hastalığı
**DÖ** : Derin Öğrenme
**ESA** : Evrişimli Sinir Ağları
**HBB** : Hafif Bilişsel Bozukluk
**KG** : Kontrol Grubu
**MR** : Manyetik Rezonans
**MRG** : Manyetik Rezonans Görüntüleme
**MÖ** : Makine Öğrenmesi
**PET** : Pozitron Emisyon Tomografisi
**PSO** : Parçacık Sürü Optimizasyonu
**PP** : Percentage Point
**RoI** : Region on Interest
**ROC** : Alıcı İşletim Karakteristiği
**RELU** : Rectified Linear Unit
**ÜRA** : Üretken Rekabetçi Ağlar

**TÖ** : Transfer Öğrenme

**TSA** : Tekrarlayan Sinir Ağları

**YSA** : Yapay Sinir Ağı

**YZ** : Yapay Zeka

# ÖZET

## YÜKSEK LİSANS TEZİ

### ALZHEİMER TANISI İÇİN DERİN ÖĞRENME TABANLI ANALİZ

**Ravza Begüm ATAK**

**İstanbul Üniversitesi-Cerrahpaşa**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Bilgisayar Mühendisliği, Tezli Yüksek Lisans Programı**

**Danışman: Doç. Dr. Muhammed Ali AYDIN**

**II. Danışman : Dr. Öğr. Üyesi Muhammed Erdem İSENKUL**

Alzheimer, dünyanın her ülkesinde önde gelen ölüm nedenleri arasında yer almaktadır. Bununla birlikte, Alzheimer tanısı zor bir hastalıktır. Çünkü semptomları diğer yaşlılık belirtileriyle sıkça karıştırılabilir. Alzheimer tanısı için tek ve kesin bir yöntem bulunmamakla birlikte, birden fazla faktörün dikkate alındığı kapsamlı bir değerlendirme yapılması önemlidir. Özellikle Alzheimer'ın erken evrelerde teşhisi hem hastanın hem de yakınlarının hastalığı daha iyi yönetmeleri ve planlamaları için gereklidir. Bu sayede gerekli önlemler ve tedbirler alınabilir.

Makine öğrenimi, derin öğrenme ve diğer yapay zeka biçimlerinin hızla yükselişi, medikal görüntü işleme alanında büyük ilerlemelere yardımcı olmaktadır. Bu paralelde yapay zeka alanındaki araştırmalar giderek artan bir yoğunluk kazanmaktadır. Derin öğrenme insan sinir ağlarından ilham alarak birçok yapay nöron katmanından oluşan bir makine öğrenmesi yaklaşımıdır. Derin öğrenme temelli yöntemler, çeviri işlemlerinden metin yazma hizmetlerine, otonom sürüş sistemlerinden endüstriyel robotlara, sağlık hizmetlerinden pazarlama ve satışa kadar birçok alanda yoğun bir şekilde kullanılmaktadır.

Bu tez çalışmasında, makine öğrenimi tabanlı farklı yaklaşımlar kullanılarak Alzheimer Hastalığı'nın erken tanısı için yeni mimariler önerilmektedir. Önerilen mimariler, Alzheimer tanısı için evrişimli sinir ağı yöntemlerinden faydalanmaktadır. Beyin tarama görüntüleri, üç kategorili bir sınıflandırma işlemi yapılarak Alzheimer, hafif bilişsel bozukluk ve kontrol grubu olarak yüksek doğruluklarla ayıklanmıştır. Veri kümesi, çeşitli veri artırma yöntemleri ile genişletilerek modeller beslenmektedir. Veriler, farklı katmanlardan oluşan özgün bir

evrişimli sinir ağı mimarisi ve çeşitli transfer öğrenme tabanlı özellik çıkarıcıların kullanıldığı altı farklı model ile test edilmektedir. Ayrıca, transfer öğrenme tabanlı yöntemlerin performanslarını artırmak için özgün bir sinir ağı tabanlı sınıflandırıcıya bağlanmıştır. Bu şekilde birçok farklı yöntem tez kapsamında test edilmiştir. Sonuç olarak, Xception ve VGG19 tabanlı ön eğitilmiş modellerimize, tasarımımız olan sınıflandırıcımız bağlandığında yüksek doğruluk oranlarıyla başarılı bir Alzheimer erken tanısı modeli elde edilmiştir.

Ağustos 2024 , 101 sayfa.

**Anahtar kelimeler:** Makine öğrenmesi, Derin öğrenme, Alzheimer

# ABSTRACT

## M.Sc. THESIS

### DEEP LEARNING BASED ANALYSIS FOR ALZHEIMER'S DIAGNOSIS

**Ravza Begüm ATAK**

**İstanbul University-Cerrahpaşa**

**Institute of Graduate Studies**

**Department of Computer Engineering**

**Computer Engineering Master's Program with Thesis**

**Supervisor : Assoc. Prof. Dr. Muhammed Ali AYDIN**

**Co-Supervisor: Assist. Prof. Dr. Muhammed Erdem İSENKUL**

Alzheimer is among the leading causes of death in every country in the world. However, Alzheimer is a difficult disease to diagnose because its symptoms can often be confused with other signs of old age. While there is no single definitive method for diagnosing Alzheimer, it is important to carry out a comprehensive assessment that takes into account multiple factors. In particular, early diagnosis of Alzheimer's disease is essential for both the patient and their relatives to better manage and plan for the disease. In this way, the necessary precautions and measures can be taken.

The rapid rise of machine learning, deep learning, and other forms of artificial intelligence is helping to drive major advances in medical image processing. In parallel, research in the field of artificial intelligence is gaining increasing intensity. Deep learning is a machine learning approach that consists of many layers of artificial neurons inspired by human neural networks. Deep learning-based methods have been extensively used in many fields, from translation to text authoring services, from autonomous driving systems to industrial robots, and from healthcare to marketing and sales.

In this thesis, new architectures for the early diagnosis of Alzheimer's disease are proposed using different machine learning-based approaches. The proposed architectures utilize convolutional neural network methods for Alzheimer's diagnosis. Brain scan images are classified into three categories with high accuracy: Alzheimer's, mild cognitive impairment, and control groups. The dataset is augmented with various data augmentation methods to train

the models. The data is tested with six different models using a novel convolutional neural network architecture with different layers and various transfer learning-based feature extractors. Furthermore, to improve the performance of the transfer learning-based methods, they are connected to a novel neural network-based classifier. In this way, many different methods are tested in this thesis. As a result, a successful Alzheimer's early diagnosis model with high accuracy rates was obtained when our designed classifier was connected to our Xception and VGG19-based pre-trained models.

August 2024, 101 pages.

**Keywords:** Machine learning, Deep learning, Alzheimer

# 1. GİRİŞ

Alzheimer hastalığı (AH), dünya çapında özellikle yaşlanan popülasyonlarda halk sağlığı açısından giderek artan bir sorun teşkil etmektedir. İlerleyen bir nörodejeneratif bozukluk olan AH, beyinde bilişsel gerilemeye, hafıza kaybına ve işlevsel bozulmaya yol açmakta; zamanla etkilenen bireylerin ve onlara bakan kişilerin yaşam kalitesini ciddi şekilde olumsuz etkilemektedir (Derby, 2020; Sehar ve diğ., 2023; Vinze ve diğ., 2023). AH' nin yaygınlığının önümüzdeki yıllarda dramatik bir şekilde artması beklendiğinden, etkisini hafifletmek için etkili teşhis araçlarına ve müdahalelere acil ihtiyaç vardır (Tahami ve diğ., 2022; Kerwin ve diğ., 2022).

Tıbbi görüntüleme yöntemleri arasında özellikle manyetik rezonans görüntüleme (MRG), Alzheimer ile ilişkili beyindeki yapısal ve işlevsel değişiklikleri anlamak için değerli bir araç olarak ortaya çıkmıştır (Warren ve Moustafa, 2023; Song ve diğ., 2024). MRG, beyin anatomisi ve patolojisinin ayrıntılı bir şekilde görüntülenmesini sağlayarak hekimlerin nörodejeneratif hastalıkların göstergesi olan ince değişiklikleri tespit etmesine olanak tanır (Pathak ve diğ., 2021; Kim ve diğ., 2022). Bununla birlikte AH tanısı için MRG taramalarının doğru bir şekilde yorumlanması, genellikle eğitimli radyologlar tarafından yapılan niteliksel değerlendirmelere dayanan karmaşık ve zorlu bir görev olmaya devam etmektedir (Yamanakkanavar ve diğ., 2020).

Son yıllarda Derin Öğrenme'nin (DÖ) ortaya çıkışı, tıbbi görüntü analizinde devrim yaratarak, AH tanısının doğruluğunu ve verimliliğini artırmak için umut verici bir yol sunmuştur (Abdou, 2022; Ünlüleblebici, 2023; Hanbay, 2023; Suganyadevi ve diğ., 2024). DÖ modelleri, özellikle evrişimli sinir ağları (ESA), büyük ölçekli görüntüleme veri kümelerinden karmaşık desenleri ve özellikleri öğrenmede üstün olup, tıbbi görüntülerin otomatik ve nesnel yorumlanmasına olanak tanımaktadır (Rasool ve Bhat, 2024). Derin ESA'lar tarafından öğrenilen hiyerarşik temsillerden yararlanılarak, AH'nin göstergesi olan ince yapısal anormallikleri ayırt etmek mümkün hale gelir. Bu da potansiyel olarak daha erken ve daha doğru tanıya olanak tanır (Suganyadevi ve diğ., 2024; Khojaste-Sarakhsi ve diğ., 2022).

Bu tezin temel amacı, AH'nin MRG taramalarında tespit edilmesi için DÖ modellerinin uygulanmasını araştırmak ve erken AH tanısı gerçekleştirmek için başarılı bir DÖ modeli geliştirmektir. Spesifik olarak, AH patolojisiyle ilişkili karakteristik özellikleri tanımlamak için beyin manyetik rezonans (MR) görüntülerini otomatik olarak analiz edebilen DÖ çerçeveleri geliştirme ve değerlendirme amaçlanmaktadır. Gelişmiş DÖ tekniklerinin en son teknolojiye sahip MRG yöntemleriyle entegrasyonu yoluyla, AH tespitinin duyarlılığını ve özgüllüğünü artırmayı, sonuçta erken müdahaleyi ve kişiselleştirilmiş tedavi stratejilerini kolaylaştırmayı hedeflemektedir. Tıbbi görüntüleme ve DÖ alanındaki önceki çalışmaların temellerine dayanan bu çalışma, AH tanısının ortaya çıkardığı belirli zorlukları ele alacak şekilde metodolojisini genişletmektedir. Hem sağlıklı bireylerden hem de AH tanısı almış hastalardan alınan görüntüleme verilerini içeren, herkese açık MRG veri kümelerinden yararlanarak, normal yaşlanma ile AH ile ilişkili patolojik değişiklikleri ayırt edebilen DÖ modellerini eğitme ve doğrulama amaçlanmaktadır.

Tezin yapısı şu şekildedir: Bölüm 1'de giriş, Bölüm 2'de AH görüntüleme teknikleri ve literatürün kapsamlı bir incelemesi, Bölüm 3'te DÖ modelleri, Bölüm 4'te veri kümesi ve geliştirilen DÖ modelleri, Bölüm 5'te AH tespiti için önerilen DÖ modellerinin niceliksel performans ölçümleri ve niteliksel analizi de dahil olmak üzere deneysel sonuçlar tartışılmakta ve geliştirilen modellerin birbirleriyle karşılaştırılması yer almaktadır. Bölüm 6'da tezden elde edilen sonuçlar özetlenmekte ve önerilerde bulunulmaktadır.

# 2. KAVRAMSAL ÇERÇEVE

## 2.1. ALZHEİMER HASTALIĞI

AH, beyni etkileyen, bilişsel gerilemeye ve hafıza kaybına yol açan ilerleyici bir nörodejeneratif hastalıktır (Karabay ve Çavaş, 2022). İlerleyici bir hastalık türü olan AH'nin kısa sürede tanısı, beyinde ciddi hasarların önlenmesi açısından kritik öneme sahiptir. AH, demans türleri arasında en yaygın olanıdır ve demans vakalarının yaklaşık %60-80'ini oluşturur (Karakuş, 2020). Hastalık ilk kez 1906'da Alman psikiyatrist ve nöropatolog Alois Alzheimer tarafından tanımlanmıştır (Ciurea, 2023).

AH, beyinde iki anormal protein parçasının birikmesiyle karakterize edilir: beta-amiloid plaklar ve tau yumakları (Xie ve diğ., 2022). Bu protein kümeleri, nöronlar arasındaki iletişimi bozar ve sonuçta nöron ölümüne ve beyin atrofisine yol açar (Karabay ve Çavaş, 2022).

AH'nin semptomları genellikle yavaş yavaş gelişir ve zamanla kötüleşir. Erken belirtiler arasında hafif unutkanlık görülmekte olup, isimleri veya randevuları hatırlamak gibi basit bilişsel işlev gerektiren görevlerde yaşanan zorluklar bulunabilmektedir. Hastalık ilerledikçe bireylerde derin hafıza kaybı, yönelim bozukluğu, davranış ve kişilik değişiklikleri yaşanabilir (Thamizharasi ve Lakshmi, 2022).

AH'nin kesin nedeni tam olarak anlaşılamamakla birlikte çeşitli risk faktörleri tespit edilmiştir. Bunlar arasında yaş, genetik yatkınlık, ailede AH öyküsü, kardiyovasküler hastalık, diyabet, obezite ve sigara içme gibi belirli yaşam tarzı faktörleri bulunmaktadır (Khojaste-Sarakhsi ve diğ., 2022).

AH tipik olarak üç ana aşamaya ayrılır: erken (hafif), orta ve geç (şiddetli). Erken aşamalarda bireyler, fark edilmeyen veya normal yaşlanmaya atfedilebilecek ince bilişsel değişiklikler yaşayabilir. Hastalık ilerledikçe semptomlar daha belirgin hale gelir ve günlük aktivitelere müdahale eder. Sonuç olarak, hafıza, dil, muhakeme ve motor fonksiyonlarda ciddi bozulmalara yol açar (Ebrahimighahnavieh ve diğ., 2020).

### 2.1.1. Alzheimer Hastalığı Semptomları

AH, zamanla ilerleyen ve geri dönüşü olmayan bir nörolojik hastalıktır. AH'nin belirtileri, hastalığın evresine ve kişiye göre değişiklik gösterebilir. Ancak dikkat edilmesi gereken ortak belirti ve semptomlar vardır. Ara sıra hafıza kaybı veya unutkanlık yaşamanın mutlaka AH'ye işaret etmediğini bilmek gerekir. Ancak kalıcı veya kötüleşen semptomlar olması durumunda bir sağlık uzmanı tarafından daha ileri bir değerlendirme yapılması gerektiği unutulmamalıdır. AH ile ilişkili bazı yaygın semptomlar şunlardır: hafıza kaybı, problem çözme ve planlamada zorluk, tanıdık görevleri tamamlamada zorluk, kafa karışıklığı ve yönelim bozukluğu, dil sorunları, ruh halinde veya kişilikte değişiklikler, sosyal aktivitelerden çekilme, eşyaları yanlış yerleştirme, karar verme yeteneğinin azalması, uyku düzenindeki değişiklikler gibi örnekler verilebilir (Gao ve Lima, 2022; Khojaste-Sarakhsi ve diğ., 2022).

AH'nin semptomlarının kişiden kişiye değişebileceğini ve herkesin yukarıda sıralanan semptomların tümünü yaşamayabileceğini unutmamak gerekir. Ek olarak, hastalık çeşitli aşamalardan geçtikçe semptomlar zamanla kötüleşebilir. Erken teşhis ve müdahale, yaşam kalitesinin iyileştirilmesine ve uygun destekle tedavi seçeneklerine erişim sağlanmasına yardımcı olabilir (Ebrahimighahnavieh ve diğ., 2020).

### 2.1.2. Alzheimer Hastalığı Tanı Teknikleri

AH'nin teşhisi, semptomların, tıbbi öykünün ve bilişsel işlevlerin kapsamlı bir değerlendirmesini içerir. Sıklıkla demansın diğer potansiyel nedenlerinin araştırılmasını gerektirir (Fathi ve diğ., 2022). Sağlık uzmanları, tanıya ulaşmak için tekniklerin ve değerlendirmelerin bir kombinasyonunu kullanır. AH için bazı yaygın tanı teknikleri olarak tıbbi geçmiş ve fiziksel muayene, bilişsel değerlendirme, nöropsikolojik testler, beyin görüntüleme, beyin omurilik sıvısı analizi, genetik test, laboratuvar testleri ve fonksiyonel değerlendirme kullanılmaktadır (Al-Shoukry ve diğ., 2020; Saleem ve diğ., 2022). Bunları kısaca inceleyecek olursak:

- **Tıbbi Geçmiş ve Fiziksel Muayene:** Teşhis süreci tipik olarak, ailede demans veya bilişsel gerileme öyküsü de dahil olmak üzere bireyin tıbbi geçmişinin kapsamlı bir şekilde incelenmesiyle başlar.

- **Bilişsel Değerlendirme**: Bilişsel değerlendirmeler, hafızayı, dikkati, dili, görsel-uzaysal becerileri ve diğer bilişsel işlevleri değerlendirmek için kullanılır.

- **Nöropsikolojik Testler:** Nöropsikolojik testler, hafıza, muhakeme, problem çözme ve yürütme işlevi dahil olmak üzere bilişsel işlevlerin derinlemesine değerlendirilmesini içerir.

- **Beyin Görüntüleme:** AH ile ilişkili beyin yapısı ve işlevindeki değişiklikleri tespit etmek için MRG veya pozitron emisyon tomografisi (PET) taramaları gibi görüntüleme çalışmaları yapılabilir.

- **Beyin Omurilik Sıvısı Analizi:** Bazı durumlarda, analiz için beyin omurilik sıvısını toplamak amacıyla lomber ponksiyon (omurilik musluğu) yapılabilir.

- **Genetik Test:** Genetik test genellikle AH'yi teşhis etmek için tercih edilen bir yöntem olmasa da özellikle ailede AH öyküsü veya diğer genetik risk faktörleri varsa önerilebilir.

- **Laboratuvar Testleri:** Tiroit fonksiyon bozukluğu, vitamin eksiklikleri veya enfeksiyonlar gibi bilişsel bozulmaya katkıda bulunabilecek diğer tıbbi durumları engelleyebilmek için kan testleri istenebilir.

- **Fonksiyonel Değerlendirme:** Fonksiyonel değerlendirme, bireyin günlük yaşam aktiviteleri, giyinme, bakım yapma, yemek pişirme ve mali durumu yönetme gibi günlük yaşamın araçsal aktivitelerini gerçekleştirme becerisinin değerlendirilmesini içerir (Al-Shoukry ve diğ., 2020; Saleem ve diğ., 2022; Fathi ve diğ., 2022).

AH'nin erken teşhis ve tanısı, zamanında müdahaleye, uygun tedavilere erişime, bireylerin ve ailelerinin AH ile ilişkili zorluklarla başa çıkmalarına yardımcı olacak destekleyici bakım stratejilerinin uygulanmasına olanak tanır.

### 2.1.3. Alzheimer Hastalığı Tanısında Güncel Durum ve Zorluklar

AH'nin teşhisini çevreleyen mevcut durum hem ilerlemeyi hem de süregelen zorlukları ortaya koymaktadır. Son yıllarda AH için biyo-belirteçlerin geliştirilmesinde önemli ilerlemeler kaydedilmiştir (Arya ve diğ., 2023; Warren ve Moustafa, 2023). Bunlar, beyindeki beta-amiloid plakları ve tau düğümlerini saptamak için PET taramaları gibi görüntüleme tekniklerinin yanı sıra, Alzheimer patolojisiyle ilişkili biyo-belirteçlerin seviyelerini ölçmek için beyin omurilik sıvısı analizini içermektedir (Zhao ve diğ., 2023). İlaveten, AH'ye bağlı HBB için revize edilmiş kriterler ve biyo-belirteç kanıtlarının teşhis kılavuzlarına dahil edilmesi gibi teşhis kriterlerinde güncellemeler görülmüştür (Jo ve diğ., 2019). Biyo-belirteç

araştırmaları ve tanı kriterlerindeki ilerlemelere rağmen, PET görüntüleme ve BOS analizi gibi özel tanı kaynaklarına erişim birçok bölgede sınırlı kalmaktadır (Sharma ve diğ., 2023). Bu durum, sağlık hizmeti sağlayıcıları için AH'nin doğru şekilde teşhis edilmesinde zorluk yaratabileceği gibi, teşhis ve tedavinin başlatılmasında gecikmelere de neden olabilir.

AH'nin erken teşhisinin önemi hakkında farkındalığın arttırılması konusuna giderek daha fazla vurgu yapılmaktadır (Shastry ve diğ., 2022). Halk sağlığı kampanyaları ve eğitim girişimleri, AH'li bir bireyin yakınlarının farkındalığının artmasına yardımcı olmaktadır. Ayrıca, gelişen teknoloji ile AH'nin teşhisinde önemli ilerlemeler kaydedilmiş olsa da, özel teşhis kaynaklarına sınırlı erişim, klinik sunumdaki değişkenlik, yanlış teşhis, multidisipliner iş birliği ihtiyacı ve devam eden araştırma boşlukları gibi hala ele alınması gereken birçok zorluk bulunmaktadır (Yamanakkanavar ve diğ., 2020; Mahajan ve diğ., 2020).

### 2.1.4. Alzheimer Hastalığı Teşhisinde Kullanılan Görüntüleme Teknikleri

Nörodejeneratif bir hastalık olan AH'nin özellikle erken evrelerinde kesin olarak teşhisi zorlu bir görevdir. Farklı bilişsel hastalıklarla karıştırılma ihtimali bulunmaktadır. Burada görüntüleme teknikleri, tanıya yardımcı olmada ve hastalığın ilerlemesini izlemede çok önemli bir rol oynamaktadır. Yaygın olarak kullanılan bazı görüntüleme teknikleri şunlardır: Bilgisayarlı Tomografi (BT), PET, MRG (Al-Shoukry ve diğ., 2020). Bu görüntüleme teknikleri, AH teşhisinde klinik değerlendirmeleri ve bilişsel testleri tamamlayarak, beyindeki durumla ilişkili yapısal, işlevsel ve moleküler değişiklikler hakkında önemli bilgiler sağlamaktadır. Hekime tanı konusunda yardımcı olmaktadır.

#### *2.1.4.1. Bilgisayarlı Tomografi*

BT, 1970'lerin başında katkılarından dolayı 1979'da Nobel Fizyoloji veya Tıp Ödülü'nü paylaşan İngiliz mühendis Sir Godfrey Hounsfield ve Güney Afrikalı fizikçi Allan Cormack tarafından geliştirilmiştir (Kreel, 2008). BT, farklı açılardan alınan X-ışını ölçümlerini birleştiren ve vücudun belirli bölgelerinin kesitsel görüntülerini oluşturmak için bilgisayarlı işlemeyi kullanan bir tıbbi görüntüleme tekniğidir (Wahlund, 1996). Bu görüntüler, standart röntgenlere göre daha ayrıntılı bilgi sağlayarak daha iyi teşhis ve tedavi planlamasına olanak tanır.

Bir BT tarayıcısı, hastanın etrafında dönen ve vücuda X-ışınları yayan bir X-ışını kaynağı kullanır (Zeng ve diğ., 2021). X-ışını kaynağının karşısındaki dedektörler vücuttan geçen X-

ışınlarını yakalar. Emilen X-ışınlarının miktarı, doku yoğunluğuna göre değişir. Dedektörler, emilim verilerini, dilimler olarak bilinen kesitsel görüntüler oluşturmak için bilgiyi işleyen bir bilgisayara gönderir. Gelişmiş algoritmalar bu dilimleri iç yapıların ayrıntılı görüntülerine yeniden yapılandırır. Taranan alanın 3B (üç boyutlu) görüntüsünü oluşturmak için birden fazla dilim birleştirilebilir (Negied ve SeragEldin, 2022).

#### *2.1.4.2. Pozitron Emisyon Tomografisi*

PET, vücuttaki metabolik süreçlerin ayrıntılı görüntülerini sağlayan tıbbi bir görüntüleme tekniğidir. PET, pozitron yayan radyoaktif izleyiciler kullanır. Bir pozitron bir elektronla karşılaştığında yok olur ve PET tarayıcısı tarafından tespit edilen gama fotonları üretir (Shirbandi ve diğ., 2021). Genellikle, pozitron yayan bir izotop ile etiketlenmiş bir glikoz analoğu olan bir radyoizleyici hastaya enjekte edilir. Radyotracer, metabolik olarak aktif dokularda birikir. Yayılan gama fotonları algılanır ve görüntü oluşturmak için kullanılır. Bilgisayarlar, bu tespitleri metabolik aktiviteyi gösteren ayrıntılı görüntüler halinde yeniden oluşturur. PET'te uzaysal çözünürlük, BT veya MRG'den daha düşüktür (Ebrahimighahnavieh ve diğ., 2020).

YZ ve makine öğrenmesi (MÖ), PET'te görüntünün yeniden oluşturulmasını, gürültü azaltmayı ve otomatik teşhisi kolaylaştırmaktadır (Arya ve diğ., 2023). PET, modern tıpta vücudun metabolik ve fonksiyonel süreçlerine dair benzersiz bilgiler sunan, dolayısıyla çeşitli hastalıkların tanı ve tedavisine yardımcı olan güçlü bir araçtır.

#### *2.1.4.3. Manyetik Rezonans Görüntüleme*

MRG, vücuttaki organ ve dokuların ayrıntılı görüntülerini oluşturmak için güçlü manyetik alanlar ve radyo dalgaları kullanır. Hasta, güçlü bir mıknatısa sahip bir tarayıcıya yerleştirilir. Radyofrekans darbeleri, vücuttaki hidrojen çekirdeklerinin hizalamasını bozmak için uygulanır. Radyofrekans darbeleri kapatıldığında, hidrojen çekirdekleri sinyal yayarak orijinal hizalarına geri döner. Bu sinyaller, vücudun ayrıntılı kesit görüntülerini oluşturmak için bir bilgisayar tarafından algılanır ve işlenir (Warren ve Moustafa, 2023).

MRG, yumuşak dokuların yüksek çözünürlüklü görüntülerini üretme yeteneği nedeniyle klinik uygulamada yaygın olarak kullanılan çok yönlü ve güçlü bir görüntüleme yöntemidir. Bu da MRG'yi çok çeşitli koşulların teşhis edilmesinde ve izlenmesinde paha biçilemez hale getirir (Suganthe ve diğ., 2020). MRG, AH'nin tanı ve tedavisinde kritik bir araçtır ve bu

durumla ilişkili yapısal ve işlevsel değişikliklerin saptanmasına ve izlenmesine yardımcı olan beynin ayrıntılı görüntülerini sunar. AH tanısında MRG, beyin anatomisinin yüksek çözünürlüklü görüntülerini sağlayarak Alzheimer'da sıklıkla etkilenen hipokampüs gibi bölgelerdeki atrofinin (büzülmenin) belirlenmesine yardımcı olur (Rashid ve diğ., 2020).

MRG, hipokampal atrofi gibi karakteristik beyin değişikliklerini tanımlayarak Alzheimer'ın erken belirtilerini tespit edebilir. Tekrarlanan MRG taramaları, beyin atrofisinin ilerlemesini ve zaman içindeki diğer yapısal değişiklikleri izleyebilir (Altınkaya ve diğ., 2020). Şekil 2.1'de sırasıyla KG, HBB ve AH deneklerine ait MR görüntüleri sunulmaktadır. AH deneğine ait görüntüde, ok ile gösterilen hipokampüs dokusunda atrofi görülmektedir. Ayrıca AH denekte yıldız ile gösterilen ventriküller bölgesinde meydana gelen genişleme göze çarpmaktadır.

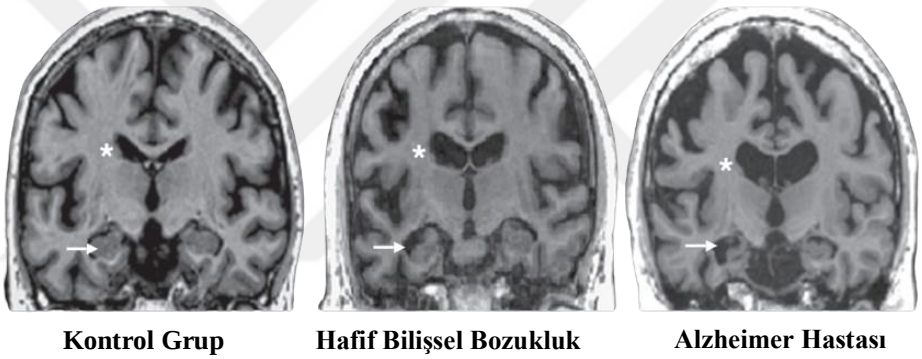


**Şekil 2.1:** Üç farklı kategoriye ait beyin MR görüntüleri (Wu ve diğ., 2011)

MRG, BT ve PET gibi yöntemler AH evrelemesi ve takibi için kullanılan görüntüleme teknikleri arasında yer almaktadır. Bu teknikler arasında MRG, kafatasının iç yapısının detaylı görüntülerini oluşturmak için güçlü bir manyetik alan ve radyo dalgalarını kullanmasından dolayı diğer tekniklere göre öne çıkmaktadır (Katti ve diğ., 2011). X-ışınları veya BT taramalarından farklı olarak, MR iyonlaştırıcı radyasyon kullanmaz. Bu da özellikle hamile kadınlar ve çocuklar gibi belirli popülasyonlarda tekrarlanan kullanımını daha güvenli hale getirir. Ek olarak, MRG beyin dokusu morfolojisindeki atrofi ve AH göstergesi olabilecek lezyonların veya anormalliklerin varlığı gibi ince değişiklikleri tespit edebilir. Böylece MRG, beyin anatomisinin daha iyi görüntülenmesini sağlayarak, AH ve diğer nörodejeneratif bozukluklardan ayırt edilmesine yardımcı olabilmektedir. Özetle, MR görüntüleme tekniği,

tıbbi alanda gelişmiş ve vücuda zarar vermeyen bir yöntem olarak diğer tekniklere kıyasla öne çıkmaktadır (LeVine, 2010).

### 2.1.5. Literatürde Yapılan Çalışmalar

YZ'nin bir alt kümesi olan DÖ, nörogörüntüleme verilerinin analizi yoluyla AH'nin erken tespiti ve teşhisinde umut vaat etmektedir. Devam eden araştırmalar, klinik uygulamalarda erken tanıyı ve hasta sonuçlarını iyileştirmeyi amaçlayan model doğruluğunu artırmaya, çok modlu verileri entegre etmeye ve modelin yorumlanabilirliğini sağlamaya odaklanmaktadır (Warren ve Moustafa, 2023; Zhao ve diğ., 2023; Rashid ve diğ., 2023). Aşağıda bu alandaki bazı çalışmalara yer verilmiştir.

DÖ modelleri, nörogörüntüleme verilerini kullanarak AH'yi tespit ve teşhis etme konusunda önemli bir potansiyel göstermektedir. Yapısal MRG temel alınarak bilgisayar destekli AH erken tanı sistemleri, hastalığın ilerlemesinin tedavisi için uygun maliyetli ve objektif bir yol olabilmektedir. Bu faydasıyla hasta ve çevresine katkı sunmaktadır. Zhang ve diğ. (2021) çalışmasında beyin büzülmesinin tanımlanmasına yardımcı olan bir ResNet tabanlı model önermektedir. Başlangıçta yerel-global ve mekansal özellikleri beyin taramalarından entegre etmek suretiyle sınıflandırma verimliliğini artırmak için bir 3B dikkat derin sinir ağı (3D ResAttNet) geliştirilmektedir. Anlaşılabilirlik özelliklerini artırmak için bir gradyan tabanlı yerelleştirme sınıf aktivasyon haritalama (g-LCAM) tabanlı anlaşılabilirlik prosedürü geliştirilmektedir. Son olarak yazarlar ardışık eğitime dayalı otomatik bir sınıflandırma yaklaşımı önermektedir. Önerilen 3B model, orijinal ResNet modelinden esinlenmektedir. En ikna edici sonuçlara ulaşmak için modelde 3B g-LCAM kullanılmaktadır.

Choi ve diğ. (2020) çalışmalarında, beyin MR verilerini kullanarak AH teşhisi için bir YSA modeli önerilmektedir. Hipokampal lobların beyin verilerinden ayrılması için 3B Slicer aracı kullanılmaktadır. Daha sonra voxel yüzeyi, Yerel Entropi Minimizasyonu bi-kübik Spline'e dayalı bir birlik düzeltme analizi ile işlenmektedir. Son olarak teşhisler ESA tabanlı bir tahmin modeli kullanılarak gerçekleştirilmektedir. Önerilen ESA giriş katmanı, evrişim katmanları, havuzlama katmanları, düzleştirme katmanları, tam bağlantılı katmanlar ve çıkış sınıf etiketini içermektedir.

Zhao ve diğ. (2020) çalışmalarında, hastalığın ilerlemesini de tahmin edebilen bir YSA tabanlı AH teşhis modeli önerilmektedir. Yaş ilerledikçe beyin değişikliklerini belirlemek için

bir 3B çok-bilgi üretici rekabetçi ağ (MulGAN) kullanılmaktadır. Alzheimer evrelerini tahmin etmek için temel olarak beyin lokalize bozulmasını optimize eden bir DenseNet tabanlı model oluşturulmaktadır. Model, yaş, cinsiyet gibi çeşitli faktörleri içermektedir. Ön işlemede, kafatası çıkarımı yapmak ve beyin görüntülerini gri madde, beyaz madde ve serebrospinal sıvı olmak üzere üç bölüme ayırmak için Voksel-tabanlı morfometri (VoBM) aracı kullanılmaktadır.

Liu ve diğ. (2018) çalışmalarında, ESA'ları tekrarlayan sinir ağlarıyla birleştirerek bir AH sınıflandırıcısı geliştirilmektedir. Tüm 3B beyin görüntüleri bir dizi 2B (iki boyutlu) dilime işlenmektedir. Sınıflandırıcıyı uygun şekilde intra-inter özellikler üzerinde uydurmak için evrişimli ve tekrarlayan sinir ağlarının bir karışımı kullanılmaktadır. Dilim bazında özellikler ESA'lar kullanılarak benimsenmiş ve çoklu özellikler, tekrarlayan sinir ağlarının kapılı tekrarlayan birimi kullanılarak benimsenmektedir.

Huang ve diğ. (2019) çalışmalarında, bir ESA tabanlı AH teşhis sistemi önermişlerdir. T1-MR ve FDG-PET verilerini kullanarak hipokampal lobların en uygun özelliklerini içeren bir ESA modeli tasarlanmaktadır. Bölme işlemleri gerçekleştirilmeden, tüm görüntü verileri eğitim ve test için aynı mekansal alana dönüştürülmektedir. Rijit normalizasyon her iki kaynaktan gelen hücrelerin aynı beyin alanlarından olduğundan emin olmak için kullanılmaktadır. Önerilen model oluşturulurken orijinal VGG modelinin konsepti referans alınmaktadır.

Lian ve diğ. (2018) çalışmalarında, beyin atrofisini önemli bir biyo-belirteç olarak kabul ederek, yeni bir AH sınıflandırma yaklaşımı tanıtılmaktadır. Model, hem atrofi tanımlaması hem de sınıflandırması için kullanılmaktadır. En ayırıcı bölgelerin belirlenmesi için küme tabanlı bir ESA tasarlanmaktadır. Tespit edilen konumlardan önemli özellikler alınmakta ve modelin eğitimi için kullanılmaktadır. Bölgesel beyin MRG kesitlerinden gelen bilgiler de modelin eğitiminde kullanılmaktadır. Her biri ekseni boyunca hizalanmış görüntülerle hücre tabanlı bir anatomik yapı oluşturularak, özellikleri çıkarmak için yaklaşık konumlar elde edilmektedir. Sonuçları iyileştirmek için bir bileşik kayıp fonksiyonu kullanılmaktadır.

Marzban ve diğ. (2020) çalışmalarında, yeni bir derin sinir ağı modeli önerilmektedir. Normalizasyon, ilgi alanı (Region of Interest-RoI) ayrımı gibi ön işlemler, istatistiksel parametrik eşlem yazılımını kullanarak gerçekleştirilmektedir. Segmentasyon yapıldıktan sonra beyin gri maddesi ve beyaz maddesi için ayrı bir hacim ölçümü gerçekleştirilmektedir.

Önerilen model, bir giriş, evrişim, grup normalizasyonu, aktivasyon, havuzlama, yoğun ve nihai sınıflandırma katmanının birleşimidir. Beş katlı çapraz doğrulama, modelin eğitim/test performansını artırmaktadır.

Zang ve diğ. (2008) çalışmalarında, MÖ algoritmalarının sınırlamalarını ele alan ve AH'yi tespit etmek için SVM tabanlı morfometrik analiz yöntemini incelemişlerdir. Modellerinin doğruluk oranlarını artırmak ve özellik boyutunu azaltmak için temel bileşen analizi (PCA) kullanılmıştır. Önerilen sistem, AH ve sağlıklı bireyleri çok yüksek doğrulukla ayırmıştır.

Dukart ve diğ. (2013) çalışmalarında, AH'nin tahmini için 3B MRG'den en uygun özellikleri elde etmede parçacık sürü optimizasyonu (PSÖ), desen arama, yarasa algoritması, benzetilmiş tavlama ve genetik algoritma gibi beş evrimsel optimizasyon algoritmasının performansını incelemektedir. Bu algoritmalar, büyük ölçekli optimizasyon problemlerine yakın-optimum çözümler elde etmek için kullanılmaktadır.

Ahmed ve diğ. (2020) çalışmalarında, AH spektrumunu aşamalandırmak için bir RoI-ESA tabanlı sınıflandırıcı önerilmektedir. Seçilen beyin bölgelerindeki (RoI) üç ortogonal görünümden alınan yama görüntüleri kullanılarak bir ESA modeli eğitilmektedir. Beyin görüntülerinden hipokampüs, amigdala ve insula bölgeleri RoI olarak seçilmektedir. AH aşamalarının olasılığını tahmin etmek için softmax aktivasyon fonksiyonu kullanılmaktadır. RoI tabanlı veriler, ikili sınıflandırmalar için bir ESA kullanılmaktadır. Daha sonra sınıflandırıcılar, AH aşamalarını belirlemek için bir araya getirilir. Veri setindeki 101 farklı RoI'den belirli 3 RoI çiftini seçmek için bir permütasyon testi yapılmaktadır.

Payan ve Montana (2015) çalışmalarında, ADNI veri kümesinden elde ettikleri 755 AH, 755 HBB ve 755 KG deneğe ait MR görüntüsünü kullanarak önceden eğitilmiş 2B ESA ve 3B ESA ile AH, HBB ve KG sınıflandırması gerçekleştirmektedir. 2B ESA kullanılarak elde edilen modelin doğruluk oranı %85,53 iken, 3B ESA ile yapılan çalışmada bu oran %89,47 olarak belirlenmektedir. Ayrıca AH ve KG ikili sınıflandırmada %95 doğruluk oranına ulaşılmaktadır.

Liu ve ve diğ. (2014) çalışmalarında, 311 adet deneğe ait MR görüntüsünden faydalanarak dört sınıflı bir veri seti üzerinde çalışılmaktadır. Çoklu sınıflandırma problemi için destek vektör makinesi tabanlı bir yöntem denenmektedir. Elde ettikleri sonuçlar değerlendirildiğinde, dört sınıf için %47,42 başarı elde edilmektedir.

Ghazal ve diğ. (2022) araştırmasında, yine dört sınıflı bir veri kümesi kullanılmıştır. 6400 AH deneğe ait MR görüntüsü üzerinden kendi önerdikleri ADDTLA isimli yöntemi test etmektedirler. Önerdikleri model %91,70 doğruluk puanı ile AH'yi başarıyla sınıflandırmaktadır.

Gray ve diğ. (2013), AH'yi sınıflandırmak için rastgele orman algoritması temelli bir yöntem önermektedir. AH sınıflandırması için MR, florodeoksi-glukoz, PET, beyin omurilik sıvısı (BOS) ve genetik bilgi biyo-belirteçlerini entegre ederek %89 doğruluk oranına ulaşılmaktadır.

Guerrero ve diğ. (2014) çalışmalarında, ADNI ve ADNI-GO veri kümeleri kullanılmaktadır. ADNI veri kümesinde dört sınıfa ait 511 görüntü, ADNI-GO veri kümesinde ise iki sınıfa ait 363 görüntü modelin beslenmesinde kullanılmaktadır. ADNI veri kümesinde %71, ADNI-GO veri kümesinde %65 doğruluk sonucu elde edilmektedir.

Dukart ve diğ. (2013) çalışmalarında, AH tanısı için SVM tabanlı bir yöntem önererek, FDG-PET ve MR görüntülerinden elde ettikleri bileşik bir veri kümesi kullanılmaktadır. Çalışmalarını ADNI veri setinden 56 deneğe ait görüntüler ve başka bir klinikten elde edilen 34 deneğe ait medikal görüntü üzerinde uygulamaktadırlar. Sonuçta MR ve FDG-PET verilerini birleştirmenin AD tespitinde kritik öneme sahip olduğu vurgulanmaktadır.

Gupta ve diğ. (2013) çalışmalarında, DÖ ve TÖ tabanlı yöntemler kullanarak AH teşhisi yapılmaktadır. Tasarımlarında tek bir evrişim ve maksimum havuzlama katmanı kullanılmaktadır. Son katmanlarını ise tek bir gizli katmana sahip bir sinir ağı tamamlamaktadır.

# 3. YÖNTEM

## 3.1. DERİN ÖĞRENME

MÖ'nün bir alt kümesi olan DÖ, verileri analiz etmek ve özellikleri otomatik olarak çıkarmak için çok katmanlı sinir ağlarını kullanır. Bu yetenek, DÖ'nün görüntü tanıma, doğal dil işleme ve tıbbi teşhis gibi çeşitli uygulamalarda geleneksel MÖ yöntemlerinden daha iyi performans göstermesini sağlar (Gautam ve Sharma, 2020). ESA'lar, tekrarlayan sinir ağları (TSA) ve üretken rekabetçi ağlar (ÜRA), DÖ'de öne çıkan bazı mimarilerdir. ESA'lar görüntüyle ilgili görevler için, TSA'lar sıralı veriler için ve ÜRA'lar veri üretimi ve geliştirmesi için yaygın olarak kullanılır (Jo ve diğ., 2019; Sharma ve diğ., 2022). DÖ, sağlık hizmetlerinde hastalıkların teşhisi için, finansal dolandırıcılık işlemleri tespiti, otonom sürüşte ve diğer birçok alanda kullanılır (Singh ve diğ., 2023). DÖ modelleri, örneğin görüntü sınıflandırma görevlerinde olduğu gibi, bazen insan performansını aşan dikkate değer bir doğruluk elde etmiştir (Zhao ve diğ., 2023; Balaji ve diğ., 2023).

### 3.1.1. Evrişimsel Sinir Ağları

ESA görüntüler gibi yapılandırılmış ızgara verilerini işlemek için özel olarak tasarlanmış bir tür DÖ mimarisidir (Tong ve diğ., 2024). ESA'lar; görüntü sınıflandırma, nesne algılama ve segmentasyon gibi çeşitli bilgisayarlı görme görevlerinde mükemmel performans sergilemiştir (Abbas ve diğ., 2023). Düşük seviyeli özelliklerden (kenarlar, dokular) başlayarak yüksek seviyeli özelliklere (nesneler, desenler) kadar verilerdeki mekansal hiyerarşileri yakalayarak çalışırlar.

Yakın zamanda yapılan bir literatür incelemesi, ESA'ların büyük ölçekli görsel verileri verimli bir şekilde işleme yetenekleri nedeniyle görüntü sınıflandırmasında baskın bir yaklaşım olmaya devam ettiğini vurgulamaktadır (SinhaRoy ve Sen, 2024; Pradhan ve diğ., 2024; Bi ve diğ., 2023; Hazarika ve diğ., 2023; Lakhan ve diğ., 2023).

Temel olarak ESA'lar, giriş görüntüsünden özellikler çıkarmak için filtreler uygulayan evrişimli katmanlar, önemli bilgileri korurken uzamsal boyutları azaltan havuzlama katmanları ve son sınıflandırmayı gerçekleştiren tamamen bağlantılı katmanlar dahil olmak

üzere çeşitli katmanlardan oluşurlar (Thangavel ve diğ., 2023; Ebrahimi ve diğ., 2021; Al-Adhaileh, 2022).

#### *3.1.1.1. Evrişim Katmanı*

Evrişim katmanı, DÖ de kullanılan ESA'ların temel bir bileşenidir. Görüntü, ses veya diğer ızgara benzeri yapılar olabilen giriş verilerine evrişim işlemlerini uygular (Abed ve diğ., 2019; Kanagamani ve diğ., 2023).

Evrişim katmanları, kalıpları tespit etmek için giriş verileri üzerinde kayan filtreler (çekirdekler) kullanır. Kullanılan filtreler, görüntülerdeki kenarlar, dokular ve şekiller gibi özelliklerin tanınması için gerekli olan yerel bağlantılar ve paylaşılan ağırlıklar aracılığıyla verilerdeki uzamsal hiyerarşileri yakalar (Nawaz ve diğ., 2021). Filtreler, RGB görüntüleri için üç kanal gibi, giriş verilerinin derinliğiyle eşleşmelidir. Her filtre tek bir özellik haritası üretir ve birden fazla özellik haritasının üretilmesi için birden fazla filtre uygulanır (Allioui ve diğ., 2020; Awarayi ve diğ., 2024).

Yığılmış evrişim katmanları, ESA'ların ilk katmanlardaki basit kenarlardan daha derin katmanlardaki karmaşık şekillere ve nesnelere kadar hiyerarşik özellikleri öğrenmesine olanak tanır. Bu hiyerarşik öğrenme, nesne tanıma ve sınıflandırma gibi görevler için çok önemlidir (Mehmood ve diğ., 2020; Ajagbe ve diğ., 2021). Evrişim işlemleri Keras gibi araçlar kullanılarak görselleştirilebilir. Örneğin, tek boyutlu bir evrişim katmanı, sıralı verilerdeki kalıpları tespit edebilir; bu da evrişimli katmanların çeşitli giriş verisi türleri arasında nasıl genelleştirildiğini gösterir (Kundaram ve Pathak, 2021; Yuvaraj ve diğ., 2023; Roy ve diğ., 2019).

Evrişim katmanlarındaki gelişmeler, hesaplama verimliliğini ve performansını artırmaya, daha hızlı ve daha doğru derin öğrenme modellerine olanak sağlamaya odaklanmaktadır. Buna filtre tasarımı, katman istifleme ve etkinleştirme fonksiyonlarındaki optimizasyonlar da dahildir (Chitradevi ve Prabha, 2020). Bu yönler, modern sinir ağı mimarilerindeki evrişim katmanlarının çok yönlülüğünü ve gücünü vurgulayarak, görüntü işleme ve diğer alanlardaki birçok son teknoloji modelin temelini oluşturur. Şekil 3.1'de evrişim işlemi gösterilmektedir. Burada giriş verisi üzerinde bir filtre dolaştırılmaktadır.

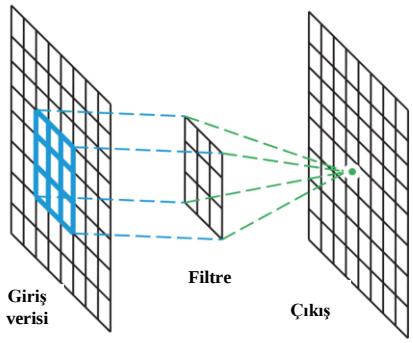


**Şekil 3.1:** Evrişim katmanı (Yakura ve diğ., 2018).

### *3.1.1.2. Havuzlama Katmanı*

Havuzlama katmanı, özellik haritalarının mekansal boyutlarını azaltmak ve önemli bilgileri korurken hesaplama maliyetlerini en aza indirmek için tasarlanmış önemli bir ESA bileşenidir (Kundaram ve Pathak, 2021). Havuzlama işlemleri, genellikle maksimum havuzlama veya ortalama havuzlama gibi türleri kullanarak giriş özellik haritasının alt örneklenmesiyle gerçekleştirilir (Wang ve diğ., 2018).

Havuzlama katmanları, özellik haritalarının boyutunu azaltır; bu sayede ağdaki parametre ve hesaplama sayısını azaltarak eğitim ve çıkarım sürelerinin daha hızlı olmasını sağlar (Acharya ve diğ., 2021). Havuz katmanları, uzamsal boyutu azaltarak, modeli giriş verilerindeki küçük değişikliklere karşı daha az duyarlı hale getirerek aşırı uyumun önlenmesine yardımcı olur (Zafar ve diğ., 2022). Havuzlama, bir tür çeviri değişmezliği sağlayarak modeli giriş görüntülerindeki kaymalara ve bozulmalara karşı daha dayanıklı hale getirir (Nawaz ve diğ., 2021). Çeşitli havuzlama işlemleri modellerde uygulanabilmektedir. Bunlar:

**Maksimum havuzlama**: Bu yöntemde her havuzlama penceresinden maksimum değeri seçer. Bu sayede evrişimli katmanlar tarafından tespit edilen en belirgin özelliklerin korunmasına yardımcı olur (Acharya ve diğ., 2021).

**Ortalama havuzlama:** Bu teknikte havuz oluşturma penceresindeki tüm değerlerin ortalamasını hesaplar. Bu yöntem, özelliklerin yumuşatılmasında yararlı olur (Wang ve diğ., 2018). Şekil 3.2'de maksimum ve ortalama havuzlama işlemleri gösterilmektedir.

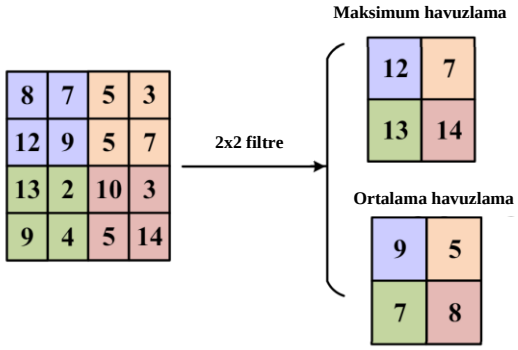


**Şekil 3.2:** Maksimim ve ortalama havuzlama işlemi (Yingge ve diğ., 2020).

**Küresel havuzlama:** Yöntem, özellik haritasının tamamındaki maksimum veya ortalamayı alarak her özellik haritasını tek bir değere indirir. Giriş boyutundan bağımsız olarak sabit boyutlu bir çıktı oluşturmak için genellikle tamamen bağlı katmanlardan önce kullanılır (Roy ve diğ., 2019).

Çeşitli havuzlama teknikleri uygulanarak, ESA'lar yüksek boyutlu verileri verimli bir şekilde işleyebilir. Veriler işlendikten sonra ilgili özellikler çıkarılarak modelin genel performansı ve sağlamlığı geliştirilebilir (Raza ve diğ., 2023; Patil ve diğ., 2022; Ashraf ve diğ., 2021).

#### *3.1.1.3. Tam Bağlı Katman*

ESA'da yoğun katman olarak da bilinen tam bağlantılı katman, genellikle ağ mimarisinin sonuna doğru yerleştirilir (Salehi ve diğ., 2020). Giriş verilerinin yerel bölgelerinde çalışan evrişimli katmanlardan farklı olarak, tam bağlantılı katmanlar bir katmandaki her nöronu bir sonraki katmandaki her nörona bağlar. Böylece tam bağlantılı bir grafik oluşturur.

Tam bağlı katmanlar, daha önceki evrişim ve havuzlama katmanları tarafından oluşturulan özellik haritalarındaki küresel modellerin öğrenilmesinden sorumludur (Kundaram ve Pathak, 2021). Bu katmanlar tarafından çıkarılan üst düzey özellikleri alıp, bunları çıktı sınıflarına veya regresyon değerlerine eşlerler (Raza ve diğ., 2023). Ağın giriş verilerinden karmaşık modelleri ve temsilleri öğrenmesini sağlayarak, yüksek düzeyde özellik çıkarımına ve doğru tahminlere yol açarak ESA'lar için çok önemli bir rol oynarlar. Tam bağlantılı katmanlar, nöronlar arasındaki yoğun bağlantı nedeniyle çok sayıda parametre içerir. Bu parametreler, stokastik gradyan inişi veya onun çeşitleri gibi optimizasyon algoritmaları kullanılarak eğitim sırasında öğrenilir (El-Assy ve diğ., 2024; Kaya ve Çetinkaya ve diğ., 2024).

Özellik haritaları, son evrişimli veya havuzlama katmanından tamamen bağlı katmana geçmeden önce genellikle tek boyutlu bir vektör halinde düzleştirilir. Düzleştirme işlemi, özellik haritalarının uzamsal yapısını korurken, bunları tamamen bağlı katman tarafından işlenmeye uygun bir formata dönüştürür (Nnah ve diğ., 2024). Tam bağlantılı bir katmanda, her nöron bir önceki katmandaki her nörona bağlanarak yoğun bir bağlantı ağı oluşturur. Her bir nöronun çıktısı, önceki katmandan gelen girdilerin ağırlıklı toplamı alınarak hesaplanır ve ardından doğrusal olmamayı sağlayacak bir aktivasyon fonksiyonu uygulanır (Ganesh ve diğ., 2023).

Tam bağlı katmanlarda kullanılan etkinleştirme işlevleri genellikle ReLU, sigmoid, tanh veya diğerleri gibi ağın diğer bölümlerinde kullanılanlara benzemektedir (Erdogmus ve Kabakus, 2023). Bu işlevler, ağa doğrusal olmayan durumlar katarak ağın verilerdeki karmaşık ilişkileri öğrenmesine olanak tanır. Denklem 3.1'de ReLU aktivasyon fonksiyonu tanımlanmaktadır (Kumar ve diğ., 2022).

$$f(x) = max(0, x) \tag{3.1}$$

Burada *x* değeri, aktivasyon fonksiyonuna giren giriş değeri ve $f(x)$ ise ReLU aktivasyon fonksiyonunun çıkış sonucudur.

Bir ESA'daki tam bağlı son katman genellikle çıktı katmanıdır. Burada nöron sayısı, bir sınıflandırma görevindeki sınıf sayısına veya bir regresyon görevindeki çıktı değerlerinin sayısına karşılık gelir. Çıkış katmanında kullanılan aktivasyon fonksiyonu, çok sınıflı sınıflandırma için softmax veya regresyon için doğrusal aktivasyon gibi görevin niteliğine bağlıdır. Denklem 3.2, softmax aktivasyon fonksiyonunu tanımlar (AlSaeed ve Omar, 2022; Salehi ve diğ., 2020).

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_j e^{z_j}} \tag{3.2}$$

Burada $z_i$, *i* sınıfına ait girdi değerini, $e$ eular sayısını, $\sigma(z_i)$ ise *i* sınıfına ait olasılık değerini temsil eder.

#### *3.1.1.4 Giriş ve Çıkış Katmanı*

ESA'lar özellikle görüntü tanıma ve sınıflandırma görevleri için çok uygun bir DÖ sınıfıdır. Giriş ve çıkış katmanlarının yanı sıra aralardaki evrişim ve havuzlama katmanları ile dikkatli

bir şekilde tasarlanan ESA'lar, görüntülerdeki desenleri ve özellikleri tanımayı etkili bir şekilde öğrenebilir (AbdulAzeem ve diğ., 2021). Bu da onları çeşitli bilgisayarlı görme görevleri için oldukça etkili hale getirir.

Bir ESA'ya giriş genellikle boyutları (yükseklik, genişlik, derinlik) olan 3B tensör olarak temsil edilen bir görüntüdür (Wang ve diğ., 2018). Örneğin, 224x224 piksel çözünürlüğe sahip bir RGB görüntüsünün giriş şekli (224, 224, 3) olacaktır.

Giriş pikseli değerleri, eğitim kararlılığını ve performansını iyileştirmek için genellikle bir aralığa (örneğin, [0, 1] veya [-1, 1]) normalleştirilir. Denklem 3.3, normalizasyon işlemi denklemidir (Patil ve diğ., 2022).

$$x' = \frac{x - \mu}{\sigma} \tag{3.3}$$

Yukarıdaki denklemde $x$, normalleştirilecek piksel değeridir. Piksel değerlerinin ortalaması ise $\mu$ ile gösterilir. Standart sapma $\sigma$ ile, $x'$ ise normalize edilmiş değerdir. Burada standart sapmayı denklem 3.4 ile hesaplayabiliriz (Lee ve Lee, 2015).

$$\sigma = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x_i - \mu)^2} \tag{3.4}$$

Yukarıdaki denklemde *N*, görüntüye ait toplam piksel sayısını ifade etmektedir.

Modeli girdideki değişikliklere karşı daha dayanıklı hale getirmek için eğitim sırasında döndürme, ölçeklendirme ve çevirme gibi teknikler kullanılabilir (Shastry ve diğ., 2022). Eğitim sırasında girdiler gruplar halinde beslenir. Örneğin 224x224x3 boyutlarında 32 görüntüden oluşan bir grup (32, 224, 224, 3) şeklinde olacaktır (Li, 2024).

Çıkış katmanının boyutları, ESA'nın gerçekleştirdiği spesifik göreve bağlıdır. Bir sınıflandırma görevi için çıktı, tipik olarak her öğenin bir sınıf olasılığını temsil ettiği 1B vektörüdür (Wang ve diğ., 2018).

### *3.1.1.5. Dropout Katmanı*

Dropout (bırakma) katmanı, ESA'larda eğitim sırasında aşırı uyumu önlemek için kullanılan bir düzenleme tekniğidir (Jiang ve diğ., 2020). Aşırı uyum, bir modelin gürültü ve aykırı değerler de dahil olmak üzere eğitim verilerini çok iyi öğrendiğinde meydana gelir (Sethi ve diğ., 2021). Aşırı uyum yapmış bir model, yeni verilerle karşılaştığında zayıf genellemesinden dolayı performansı düşüktür. Dropout, ağın belirli nöronlara karşı daha az duyarlı olmaya zorlayarak ezberleme durumunun hafifletilmesine yardımcı olur (Kaur ve diğ., 2022).

Dropout katmanı, eğitim sırasında nöronları rastgele bırakarak ağdaki nöronların belirli aktivasyonlara bağlı olmayan daha sağlam özellikleri öğrenmeye zorlar (Yuvaraj ve diğ., 2023). Dropout katmanı, eğitim süresi boyunca her güncellemede giriş birimlerinin bir kısmını rastgele sıfıra ayarlayarak çalışır. Bu kesir, tipik olarak percentage point(pp) olarak gösterilen bir bırakma oranıyla tanımlanır. Örneğin, 0,5'lik bir bırakma oranıyla her bir nöronun ileri geçiş sırasında sıfırlanma şansı %50'dir (Jiang ve diğ., 2020; Sethi ve diğ., 2021). Test işlemi sırasında dropout uygulanmaz. Bunun yerine tam ağ kullanılır. Ancak nöronların ağırlıkları, eğitim sırasındaki ortalama etkiyi hesaba katmak için bırakma oranına göre küçültülür (Dua ve diğ., 2020). Şekil 3.2'de dropout'a ait işleme dair bir örnek gösterilmektedir.

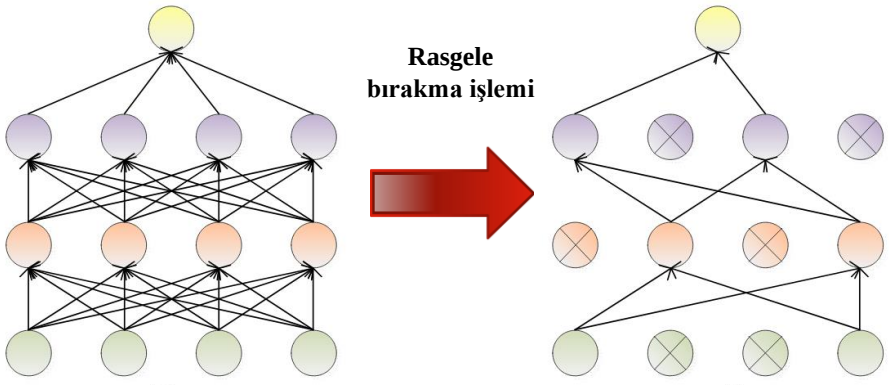


**Şekil 3.3:** Dropout işlemi (Zhang ve diğ., 2019).

### 3.1.2. Evrişimsel Sinir Ağı Mimarilerinde Kullanılan Blok Yapıları

ESA'lar, performansı, verimliliği ve genellemeyi geliştirmek için benzersiz blok yapıları sunmaktadır. ESA'lar, çeşitli mimarilerle zaman içinde gelişmektedir (Wen ve diğ., 2020;

Kang ve diğ., 2021). ESA mimarilerinde yaygın olarak kullanılan bazı blok yapıları aşağıda listelenmektedir. Bu blok yapıları, her biri gelişmiş doğruluk, verimlilik veya her ikisine birden katkıda bulunan çeşitli son teknoloji ESA mimarilerinin yapı taşlarını oluşturur. Ancak bu gelişmiş mimarilerin uygulanması sırasında "Kaybolan Gradyan Problemi" olarak bilinen bir sorun bulunmaktadır. Sorun, eğitim sırasında gradyanın giderek küçülmesi ve modelin güncellenememesi sorununu ifade eder.

#### *3.1.2.1. Kaybolan Gradyan Problemi*

Kaybolan gradyan problemi, ESA'lar dahil olmak üzere derin sinir ağlarının eğitiminde bilinen bir sorundur (Al-Adhaileh, 2022). Geri yayılım sırasında ağ parametrelerine göre kayıp fonksiyonunun gradyanları çok küçük olduğunda ortaya çıkar. Böyle bir durum, ağın ilk katmanlarının öğrenme sürecini ciddi şekilde yavaşlatabildiği gibi, hatta ağı durdurabilir. Ağın ilk katmanları, ağırlıkları minimum düzeyde güncellendiğinden çok yavaş öğrenir. Bu durum, ağın ilk katmanlardaki yararlı özellikleri öğrenmesini engeller. Ağ, özellikle çok derin ağlarda doğruluk ve performans açısından tam potansiyeline ulaşamayabilir (AbdulAzeem ve diğ., 2021).

#### *3.1.2.2. Eklemeli Bağlantı: Artık Bağlantı Modeli*

Artık bağlantı modeli veya kısayol bağlantıları olarak da bilinen ek bağlantılar, ESA'larda özellikle artık ağlar (ResNets) gibi DÖ mimarileri bağlamında temel bir kavramdır (Pei ve diğ., 2022). Artık bağlantılar, bir katmanın girişinin sonraki katmanın çıkışına eklendiği ve bilgilerin belirli katmanları atlayıp doğrudan daha derin katmanlara akmasına olanak tanıyan bir tür atlama bağlantısıdır (Ahmadi ve diğ., 2024).

Eklemeli bağlantılar, bir katmanın çıktısının gerekirse girişine yakından benzeyebildiği kimlik eşlemeyi kolaylaştırır. Böylece katmanlar arasında bilgilerin korunmasına yardımcı olur ve derin ağlarda bozulmayı önler (Thangavel ve diğ., 2023).

#### *3.1.2.3 Birleştirmeli Bağlantı: Dense Blok Modeli*

Dense blok modeli, Gao Huang ve diğ. (2017) tarafından tanıtılan DenseNet'lerin (yoğun bağlantılı evrişimli ağlar) önemli bir bileşenidir (Huang ve diğ., 2017). DenseNet'ler, ağ üzerinden bilgi akışını ve gradyanları iyileştirmek için tasarlanmıştır. Kaybolan gradyan probleminin giderilmesine ve derin ağların verimliliğinin artırılmasına yardımcı olmaktadır. Her katmanın yalnızca bir sonraki katmana bağlı olduğu geleneksel evrişimli ağlardan farklı

olarak, DenseNet'lerde her katman, önceki tüm katmanlardan girdi alır (Carcagni ve diğ., 2023). Yani, belirli bir katmana yapılan girdinin, bir araya getirilen önceki tüm katmanların özellik haritalarını içerdiği anlamına gelir.

DenseNet'lerin temel bileşenleri yoğun bloklardır. Her yoğun blokta, her katman diğer katmanlara ileri beslemeli olarak bağlanır. Yoğun bir blok içindeki her katmanın ürettiği çıktı, özellik haritalarının sayısını ifade eder. Büyüme oranı k ise her katman k özellik haritası üretir (Zhang ve diğ., 2021).

DenseNet'ler genellikle her bir evrişime yönelik giriş özelliklerinin sayısını azaltmak için darboğaz katmanlarını kullanır. Böylece hesaplama verimliliğini artırır. Bir darboğaz katmanı tipik olarak 1x1 evrişimin ardından 3x3 evrişiminden oluşur. Her katman, büyüme oranıyla tanımlanan sabit sayıda özellik haritası üretir. Bunlar daha sonra bir sonraki katmanın girdisini oluşturmak üzere girdi özellik haritalarıyla birleştirilir (Hazarika ve diğ., 2022).

#### *3.1.2.4. Inception Mimarisi*

GoogLeNet olarak da bilinen Inception mimarisi, Szegedy ve diğ. (2016) tarafından tanıtılan evrişimli bir sinir ağı mimarisidir. Inception mimarisi, derin sinir ağlarında derinlik ve hesaplama karmaşıklığı sorunlarını çözmek için tasarlanmıştır (Sharma ve diğ., 2022).

Inception mimarisinin temel yapı taşı, aynı katman içerisinde farklı boyutlardaki filtreleri kullanarak çok ölçekli özellik çıkarımı gerçekleştiren başlangıç modülüdür (Sharma ve diğ., 2021). Bu tasarım ise mimariye hem ince taneli hem de kaba taneli özellikleri verimli bir şekilde yakalamasına olanak tanır. Bir katmanda yalnızca bir evrişim işlemi kullanmak yerine, Inception modülü farklı çekirdek boyutlarına (örneğin: 1x1, 3x3, 5x5 evrişimler) ve havuzlama işlemlerine sahip birden çok paralel evrişim işlemi kullanır (Bae ve diğ., 2020). Böylece ağın birden çok ölçekteki özellikleri yakalamasını sağlar.

Hesaplama karmaşıklığını ve parametre sayısını azaltmak için daha büyük evrişimler uygulanmadan önce, boyut azaltımı için 1x1 evrişimleri kullanılır (Abed ve diğ., 2020). Bu işlemler, önemli özellikleri korurken hesaplama maliyetini azaltmaya yardımcı olur. Paralel evrişim işlemlerinin çıktıları, bir sonraki katmana beslenmeden önce derinlik boyutu boyunca birleştirilir. Bu sayede ağın farklı ölçeklerde öğrenilen özellikleri birleştirmesine ve daha zengin temsiller yakalamasına olanak tanır (Javid ve Feghhi, 2024).

### *3.1.2.5. AlexNet Mimarisi*

AlexNet, DÖ alanının ilerlemesinde önemli bir rol oynayan öncü bir ESA mimarisidir (Fu'Adah ve diğ., 2021). Krizhevsky ve diğ. (2012) tarafından geliştirilmiştir. ImageNet 2012 büyük ölçekli görsel tanıma yarışmasını (ILSVRC) kazanmıştır. Diğer yaklaşımlardan önemli ölçüde daha iyi performans göstermiştir (Simon ve diğ., 2019).

AlexNet beş evrişimli katmandan ve bunu takip eden maksimum havuzlama katmanlarından oluşur (Nawaz ve diğ., 2020). Bu katmanlar girdi görüntülerinden hiyerarşik özelliklerin öğrenilmesinden sorumludur. Her evrişim katmanından sonra ReLU aktivasyon fonksiyonları kullanılır. ReLU modele doğrusal olmama özelliğinin getirilmesine yardımcı olur ve eğitim sürecinin yakınsamasını hızlandırır.

AlexNet mimarisi, giriş verisi olarak 224x224 boyutunda RGB görüntülerini alır. Ağ, her biri bir ReLU aktivasyon fonksiyonu ve maksimum havuzlama katmanı tarafından takip edilen beş evrişimli katmandan oluşur (Kezzal ve Limene, 2022). Bırakma işlemi birinci ve ikinci tamamen bağlı katmanlardan sonra uygulanır. Bırakma, eğitim sırasında giriş birimlerinin bir kısmını rastgele sıfıra ayarlayarak modelin sağlamlığını artırır ve nöronların ortak adaptasyonunu azaltarak aşırı uyumun önlenmesine yardımcı olur (Goyal ve diğ., 2024). AlexNet, üç adet tamamen bağlantılı katmanla son bulur. Tamamen bağlı olan son katman, softmax aktivasyon fonksiyonunu kullanarak sınıf olasılıkları üretir. Softmax işlevi, ham puanları sınıf olasılıklarına dönüştürmek ve her sınıfın olasılığını belirtmek için tamamen bağlı son katmanın çıkışına uygulanır (Ali ve diğ., 2023). Şekil 3.4'te AlexNet mimarisi gösterilmektedir.

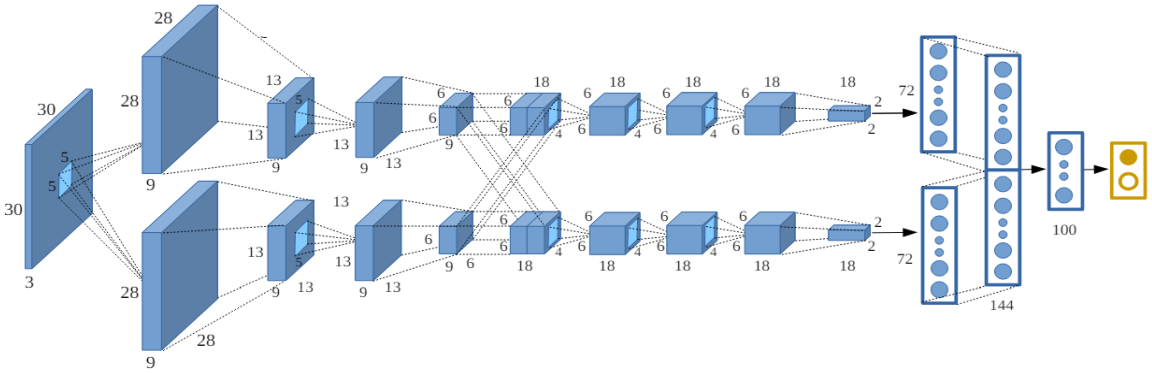


**Şekil 3.4:** AlexNet Mimarisi (Guo ve diğ., 2017)

### *3.1.2.6. VGG16 Mimarisi*

VGG16 mimarisi Oxford Üniversitesi Görsel Geometri Grubu'ndan (VGG) Simonyan ve Zisserman (2014) tarafından önerilen bir ESA mimarisidir. Temel olarak küçük 3x3 filtreli istiflenmiş evrişim katmanlarından, maksimum havuzlama katmanlarından ve ardından uçta tamamen bağlı katmanlardan oluşan basitliği ve tekdüze yapısıyla karakterize edilir (Ajagbe ve diğ., 2021). VGG16, görüntü sınıflandırma, nesne algılama ve segmentasyon dahil olmak üzere çeşitli bilgisayarlı görme görevlerinde yaygın olarak kullanılmaktadır (Ebrahim ve diğ., 2020).

VGG16 modeli, her biri bir ReLU aktivasyon fonksiyonu ve 3x3 evrişimli filtreler tarafından takip edilen 13 evrişimli katmandan oluşur (Lim ve diğ., 2022). Küçük filtre boyutu, ağın ayrıntılı mekansal bilgileri verimli bir şekilde yakalamasına olanak tanır. 2x2 filtreli ve 2 adımlı maksimum havuzlama katmanları, özellik haritalarının uzamsal boyutlarını alt örneklemek, hesaplama karmaşıklığını azaltmak ve aşırı uyumu kontrol etmek için kullanılır (Prakash ve diğ., 2019).

Evrişimli katmanları, bir vektör halinde düzleştirilinceye ve sınıflandırma için tamamen bağlantılı katmanlara beslenene kadar, özellik haritalarının uzamsal boyutlarını kademeli olarak azaltan üç adet tamamen bağlantılı katman takip eder (Bagaskara ve Suryanegara, 2021). VGG16 modeli, softmax aktivasyon fonksiyonunu kullanarak sınıf olasılıkları üreten son katmanla tamamen bağlı üç katmanla son bulur (Arafa ve diğ., 2024). Şekil 3.5'te VGG16 modelinin mimari tasarımı gösterilmektedir.

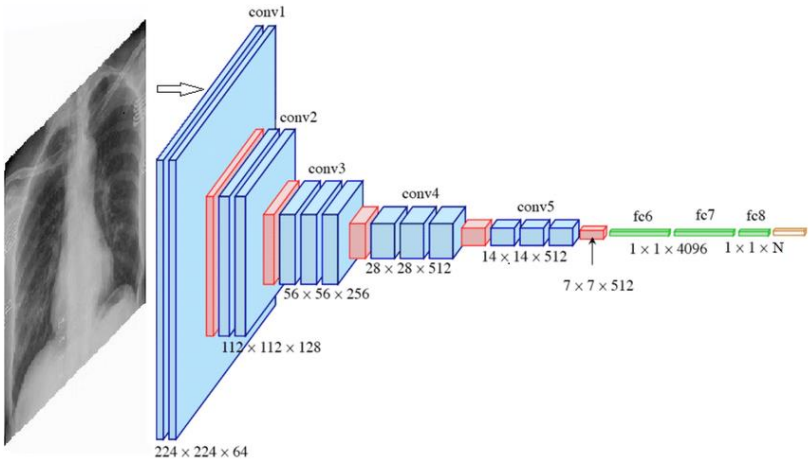


**Şekil 3.5:** VGG19 mimarisi (Yang ve diğ., 2021).

### *3.1.2.7. VGG19 Mimarisi*

VGG19, her ikisi de Oxford Üniversitesi Görsel Geometri Grubu'ndan Simonyan ve Zisserman (2014) tarafından önerilen VGG16 mimarisinin bir uzantısıdır. VGG19, VGG16'ya çok benzer ancak 19 katmanlı daha derin bir mimariye sahiptir (Bagaskara ve Suryanegara, 2021). VGG16'ya benzer şekilde, VGG19 da her biri bir ReLU aktivasyon fonksiyonu ve 3x3 evrişimli filtreler tarafından takip edilen birden fazla evrişimli katmandan oluşur (Wang ve diğ., 2021). Artan derinlik, VGG19'un daha karmaşık özellikleri öğrenmesine olanak tanır.

Maksimum havuzlama katmanları, özellik haritalarının uzamsal boyutlarını alt örneklemek, hesaplama karmaşıklığını azaltmak ve aşırı uyumu kontrol etmek için kullanılır (Assmi ve diğ., 2024). VGG19 tasarımı, özellik haritalarının uzamsal boyutlarını, bir vektör halinde düzleştirilinceye ve sınıflandırma için tamamen bağlantılı katmanlara beslenene kadar kademeli olarak azaltan, tamamen bağlantılı üç katmanla son bulur (Hazarika ve diğ., 2024). VGG19 mimari yapısı Şekil 3.6'da gösterilmektedir.

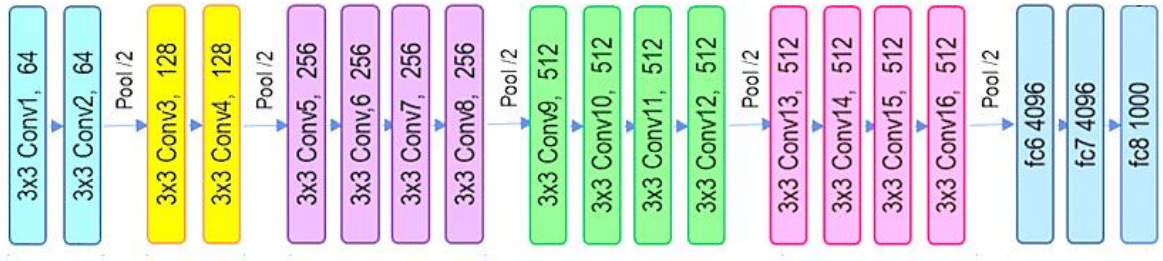


**Şekil 3.6:** VGG19 mimarisi (Khattar ve diğ., 2022).

### *3.1.2.8. Xception Mimarisi*

Xception (Extreme Inception) mimarisi, Keras DÖ kütüphanesi oluşturan Chollet (2017) tarafından önerilen bir ESA mimarisidir. Xception, derinlemesine ayrılabilir evrişimler adı verilen, evrişimli katmanlara yeni bir yaklaşım getirerek ESA'ların tasarımında bir ilerlemeyi temsil etmektedir (Francis ve Pandian, 2021). Xception, geleneksel evrişimler yerine derinlemesine ayrılabilir evrişimler kullanır. İki ayrı işlemden oluşur: derinlemesine evrişimler ve noktasal evrişimler (Ghaffari ve diğ., 2022). Derinlemesine evrişimler, her giriş kanalı kendi filtre seti ile ayrı ayrı evrilir ve bir dizi çıkış kanalı üretilir. Noktasal evrişimler, çıkış kanallarını derinlemesine evrişimlerden birleştirmek için tüm giriş kanallarına 1x1

evrişim uygulanır. Bu, kanallar arası korelasyonların yakalanmasına yardımcı olur (Sisodia ve diğ., 2023).

Derinlemesine ayrılabilir evrişimler, ağın uzamsal ve kanallar arası korelasyonları ayrı ayrı verimli bir şekilde yakalamasına olanak tanır. Xception mimarisi, derinlemesine ayrılabilir evrişimlerden önce ve sonra doğrusal darboğazlar ortaya çıkarır (Arslan ve Özdemir, 2024). Bu darboğazlar, temsil kapasitesini korurken parametre sayısını ve hesaplama maliyetini azaltmaya yardımcı olur. Diğer modern ESA mimarilerine benzer şekilde, Xception, akışı kolaylaştırmak ve derin ağların daha kolay eğitilmesini sağlamak için atlama bağlantılarını içerir. Şekil 3.7'de Xception mimarisi gösterilmektedir.

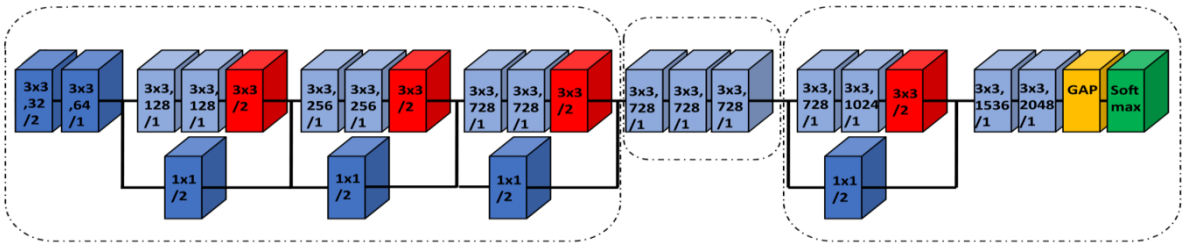


**Şekil 3.7:** Xception mimarisi (Westphal ve diğ., 2021)

Derinlemesine ayrılabilir evrişimler, geleneksel evrişimlere kıyasla parametre sayısını ve hesaplama maliyetini azaltarak Xception'ın eğitilmesini ve dağıtılmasını daha verimli hale getirir (Chaihtra ve Shetty, 2021). Xception mimarisi, modüler yapısı ve verimli tasarımı sayesinde farklı görevlere ve veri kümelerine kolaylıkla uyarlanabilir.

### *3.1.2.9. ResNet Mimarisi*

Artık ağların kısaltması olan ResNet, derin sinir ağlarının eğitim zorluğunu ele alan bir ESA mimarisidir (Roy ve diğ., 2021). He ve diğ. (2016) tarafından tanıtılmıştır. ResNet'in temel yeniliği, artık bloklarında yatmaktadır. ResNet mimarisi, giriş ve çıkış arasındaki temel eşlemeyi doğrudan öğrenmek yerine, ağın kalan işlevleri öğrenmesine olanak tanıyan artık bağlantıları sunar. Denklem 3.5'te gösterildiği üzere, matematiksel olarak bir artık bloğun çıkışı, artık fonksiyonunun girişi ve çıkışının toplamı olarak tanımlanır (Ebrahimi ve diğ., 2020).

$$y = F(x) + x \tag{3.5}$$

Burada *x* bloğun girişidir. *F(x)* bloğun evrişimli katmanlarının çıkışı (artık fonksiyon), *y* ise bloğun çıkışıdır.

ResNet mimarisinde atlama bağlantıları kimlik eşlemesi gerçekleştirir. Herhangi bir dönüşüm olmadan girişi doğrudan çıkışa aktarmaları anlamına gelir. Daha derin ResNet çeşitleri (örn. ResNet-50, ResNet-101), hesaplama karmaşıklığını azaltmak için darboğaz artık blokları kullanır. Bir darboğaz bloğu üç evrişimli katmandan oluşur: boyutsallığın azaltılması için 1x1 evrişim, özellik çıkarımı için 3x3 evrişim ve boyutluluğu geri yüklemek için başka bir 1x1 evrişim (Liu ve diğ., 2022). Tasarlanan bu mimari, ağın temsil gücünü korurken modelin verimliliğini artırır.

ResNet modeli ImageNet veri seti de dahil olmak üzere çeşitli görüntü sınıflandırma kriterlerinde, doğruluk ve verimlilik açısından birçok mimariyi geride bırakarak yüksek performansa ulaşmış bir mimaridir. ImageNet gibi büyük veri kümeleri üzerinde eğitilmiş ön eğitimli ResNet modellerine öğrenilen temsillerden yararlanılarak çeşitli bilgisayarlı görme görevleri için ince ayar yapılabilir (Logan ve diğ., 2021).

Özetle ResNet ağı derin ağların eğitiminin zorluklarını çözmek için artık bağlantılar sunan bir ESA mimarisidir. Yenilikçi tasarımı ve üstün performansı, onu bilgisayarlı görme için DÖ alanında önemli bir model haline getirmiştir (Aderghal ve diğ., 2020).

#### *3.1.2.10 Transfer Öğrenme*

TÖ, bir görev üzerinde eğitilen bir modelin, ilgili ikinci bir görevdeki model için başlangıç noktası olarak yeniden kullanıldığı bir MÖ tekniğidir. ESA bağlamında TÖ, farklı görevler veya veri kümeleri üzerinde yeni modelleri eğitmek için bir başlangıç noktası olarak ImageNet gibi büyük veri kümeleri üzerinde eğitilmiş önceden eğitilmiş ESA modellerinin kullanılmasını içerir (Chui ve diğ., 2022).

Önceden eğitilmiş ESA modelleri, görüntü sınıflandırma, nesne algılama veya görüntü bölümlendirme gibi görevler için büyük ölçekli veri kümeleri üzerinde eğitilir (Tanveer ve diğ., 2021). Eğitilen modeller görüntülerden genellikle çok çeşitli ve ilgili görevler için yararlı olan genel özellikleri çıkarmayı öğrenir.

İsteğe bağlı olarak son katmanları yeniden eğiterek veya önceki katmanlardan bazıları ayarlanarak, yeni veri kümesinde önceden eğitilmiş modelde ayar yapılabilir. Bu sayede

modelin yeni veri kümesinin belirli özelliklerine uyarlanmasına yardımcı olur (Zaabi ve diğ., 2020). Önceden eğitilmiş modellerden öğrenilen bilgilerden yararlanmak ve ESA'ların çeşitli görev ve veri kümeleri üzerindeki performansını artırmak için TÖ etkili bir şekilde uygulanabilir.

### 3.1.3. Performans Metrikleri

Performans metrikleri ESA'ların görüntü sınıflandırma, nesne algılama, görüntü bölümleme ve daha fazlası gibi çeşitli görevlerdeki etkinliğini ve doğruluğunu değerlendirmek için kullanılır (Al-Adhaileh, 2022). Farklı görevler, performansı etkili bir şekilde ölçmek için farklı ölçümler gerektirebilir. ESA'lar için yaygın olarak kullanılan bazı performans ölçümleri şunlardır (Ajagbe ve diğ., 2021; Ebrahim ve diğ., 2020; Marzban ve diğ., 2020):

✓ **Doğruluk:** Doğru sınıflandırılmış görüntülerin toplam görüntü sayısı içindeki oranını ölçer. Görüntü sınıflandırma görevleri için en yaygın kullanılan ölçümlerden biridir.

✓ **Kesinlik (Hassasiyet):** Tüm olumlu tahminler arasında gerçek olumlu tahminlerin oranını ölçer. Modelin yanlış pozitiflerden kaçınma yeteneğini temsil eder.

✓ **Geri Çağırma (Hatırlama):** Gerçek olumlu tahminlerin tüm gerçek olumlu örnekler içindeki oranını ölçer. Modelin tüm olumlu örnekleri tanımlama yeteneğini temsil eder.

✓ **F1 Puanı:** Hassasiyet ve hatırlamanın harmonik ortalamasıdır. Hassasiyet ve geri çağırma arasında bir denge sağlar.

Bu metrikleri hesaplamak için aşağıdaki parametreler bilinmelidir:

- **Doğru Pozitif (DP):** Pozitif olan örneğin doğru sınıflandırılması olarak adlandırılan işlemdir (Ör: Hastaya hasta demek).
- **Doğru Negatif (DN):** Negatif olan örneğin doğru sınıflandırılması olarak adlandırılan işlemdir (Ör: Hasta olmayana hasta değil demek).
- **Yanlış Pozitif (YP):** Negatif olan örneğin yanlış sınıflandırılması işlemidir (Ör: Hasta olmayana hasta demek).
- **Yanlış Negatif (YN):** Pozitif olan örneğin yanlış sınıflandırılması işlemidir (Ör: Hasta olana hasta değil demek).

Doğruluk formülü denklem 3.6'da, duyarlılık hesabı denklem 3.7'de ve yanlış pozitif oranı denklem 3.8'de gösterilmiştir (Ebrahimi ve diğ., 2021; Lahmiri, 2023; Tong ve diğ., 2024).

$$Doğruluk = (DP + DN) / (DP + DN + YP + YN) \quad (3.6)$$

$$Doğru\ Pozitif\ Oranı = DP / (DP + YN) \quad (3.7)$$

;

$$LO \quad (3.8)$$

;lok

# 4. BULGULAR

Tez çalışmasının bu kısmında MR beyin görüntüleri yardımıyla AH'nin erken tanısı için önerilen ESA tabanlı yedi ayrı mimari tanıtılmaktadır. Önerilen yöntemlerde modellerin beslenmesinde 2B aksiyal beyin dilimleri kullanılmıştır. Her bir model için aynı veri kümesi test edilerek modellerin eşit şartlarda performans sonuçlarının değerlendirilmesi amaçlanmıştır. Veri kümesi seçilirken özellikle beynin hipokampüs ve temporal lobunu içeren dokulara ait kesitleri içeren dilimler tercih edilmiştir. Bu dilimler ile modeller beslenmiştir.

Tez kapsamında tasarlanan birinci mimarimiz özgün bir ESA modeli olup, özellikle AH'ın HBB evresini önceden teşhis etmek amacıyla geliştirilmiştir. Bu nedenle küçük boyutlu filtreler ile model tasarlanmıştır. Özelleşmiş görevler için geliştirilen özgün mimarilerde başarılı sonuçlar elde edilebilmektedir. Bu nedenle tasarlanan mimariye ait performans metrikleri tez kapsamında yorumlanmıştır. Diğer önerilen mimarilerimizde ise TÖ tabanlı modellerin genelleme yeteneğinden faydalanmak amaçlanmıştır. TÖ tabanlı yöntemler ön eğitilmiş modelleri kullanır. Bu bağlamda TÖ tabanlı modeller farklı veri türleri ve görevleri üzerinde önceden eğitilirler. Bu sayede TÖ tabanlı modeller yeni durumlara ve görevlere daha kolay uyum sağlayabilmektedir.

AH erken tanısı için test edilen ikinci modelimiz Xception tabanlı bir TÖ modelidir. Bu modelde Xception ön eğitilmiş modeli görüntü sınıflandırma görevi için özelleştirilmiştir. Basit bir sınıflandırıcı mimari ile modelin çıkışı birleştirilmiştir. Bu sayede modelin performansı değerlendirilmiştir. Üçüncü test edilen modelimizde ise Xception tabanlı TÖ modelimize özel sınıflandırma katmanları eklenmiştir. Bu bağlamda bu modelde Xception modelimizin çıkışı, ikinci modelden daha karmaşık bir mimariye sahip bir sınıflandırıcı mimarisine bağlanmıştır. Bu sayede Xception ön eğitilmiş modelin sınıflandırma performansını artırmak amaçlanmıştır. İkinci ve üçüncü modellerde kullanılan Xception tabanlı mimari, ayrık konvolüsyonlar adı verilen bir teknik kullanır. Bu teknik modelin küçük ayrıntılara odaklanma yeteneğini artırmaktadır. Bu nedenle tez kapsamında Xception tabanlı modellerin HBB evresi tanısı için yüksek başarı elde edebildikleri görülmüştür.

Tez kapsamında dördüncü modelimiz VGG16 tabanlı bir yöntemdir. Bu yönteme ikinci modelde kullanılan basit mimari bir sınıflandırıcı eklenmiştir. VGG16 mimarisi bazı modellere kıyasla çeşitli avantajlar sunmaktadır. Ağ tasarımı, nispeten bazı mimari yaklaşımlara göre daha basittir. Ayrıca, küçük boyutlarda konvolüsyon filtreleri kullanmaktadır. Bu basitlik, modelin anlaşılmasını ve uygulanmasını kolaylaştırır. Basitliğine rağmen, VGG16'nın 16 katmanlı yapısı karmaşık özellikleri etkili bir şekilde yakalayabilmektedir. Tez için test edilen beşinci mimari tasarımımızda, VGG16'nın ön eğitilmiş mimarisi üzerine üçüncü modelde önerilen karmaşık sınıflandırıcı eklenmiştir. Bu sayede etkili bir sınıflandırma performansı elde edilmesi amaçlanmıştır. VGG16 tabanlı TÖ modellerimizde kullanılan yöntemler, tez kapsamında test edilen diğer TÖ tabanlı yöntemlere kıyasla nispeten daha basit bir mimari olarak karşımıza çıkmaktadır. Dördüncü ve beşinci modellerimizde, VGG16'nın basit mimarisinin sağlayacağı avantajdan yararlanmak istenilmiştir. Diğer modellere kıyasla görüntü detaylarından kaybedilen performans tasarlanan karmaşık sınıflandırıcı mimarisi ile giderilmeye çalışılmıştır. Böylelikle, doğruluk açısından başarılı bir model geliştirilip test edilmeye çalışılmıştır.

Tez çalışmasının ana amacı HBB evresinde hastalık teşhisidir. Özellikle tam AH evresine erişmeden önce bir bireyin beyninde oluşan minimal deformasyonların tespiti tezde amaçlanmıştır. Bu nedenle, tez kapsamında kullanılan üçüncü model Xception tabanlı bir TÖ modelidir. Model, bir özellik çıkarıcısı olarak görev yapmaktadır. Sınıflandırma işlemleri için karmaşık bir sinir ağı tabanlı sınıflandırıcı mimarisi kullanılmaktadır. Derin ve geniş yapısı sayesinde, Xception+Sınıflandırıcı modelimiz çok iyi bir performans elde etmiştir ve AH ile ilgili özellikleri başarıyla yakalayabilmiştir. Diğer bir başarılı modelimiz ise yedinci mimarimizdir. VGG19 mimarisi genellikle 3x3 boyutlarında küçük filtrelerden meydana gelmektedir. Ayrıca, VGG19 oldukça derin bir modeldir. Bu modele küçük filtrelerden oluşan sınıflandırıcımız eklenmesiyle model performansı oldukça artmıştır. Yedinci modelimiz bu tasarımıyla girdi görüntülerinden AH ile ilgili paternleri öğrenmiştir.

Tez kapsamında HBB tanısının dışında Alzheimer teşhisi de yapılmaktadır. Literatürde bu tür ikili sınıflandırma problemleri ile ilgili çalışmalar mevcuttur (Tufail ve diğ., 2020; Hussain ve diğ., 2020). Ancak AH evresine ulaşan bir hastada meydana gelen doku deformasyonları, başlangıç evresindeki bir hastaya kıyasla daha belirgindir. Bu durum, AH/KG ikili sınıflandırma problemlerinin yüksek doğrulukta başarılı sonuçlar elde edebilmesine imkân verebilmektedir. Oysaki beyin dokusundaki deformasyonların tespiti, meydana gelen

deformasyonların daha az olmasından kaynaklı olarak daha güç bir işlemdir. Ancak tez kapsamında özellikle AH'nin erken evrede teşhisi amaçlanmaktadır. Erken evre AH teşhisi hem hastalar hem de aileleri için birçok önemli fayda sağlar. Bu nedenle tez kapsamında daha zorlu bir görev olan erken evre AH teşhisi yapılmaya çalışılmıştır. Bu görev, bir çoklu sınıflandırma problemi olarak düşünülmüştür.

Tez kapsamında birinci mimarimiz olan ve kendi tasarladığımız DÖ tabanlı sınıflandırıcımız, AH/HBB/KG çoklu sınıflandırma problemi için test veri setinde %71 doğruluk başarısına sahip olmuştur. Model, F1-skoru olarak AH: 0,65; HBB: 0,65 ve KG: 0,79 puanlarını elde etmiştir. Mimarimiz %70'ten yüksek bir doğruluk başarısı elde etmiştir. Xception tabanlı ikinci modelimiz ise test veri kümesinde %91 gibi yüksek bir doğruluk oranı elde etmiştir. F1-skoru olarak ise AH: 0,91; HBB: 0,88 ve KG: 0,93 oranları elde edilmiştir. Xception ve karmaşık sınıflandırıcı tabanlı birleşik mimarili üçüncü modelimiz test veri setinde %93 gibi çok daha iyi bir doğruluk oranına ulaşmıştır. F1-skoru olarak ise AH: 0,93; HBB: 0,91 ve KG: 0,95 puanları elde edilmiştir. VGG16 tabanlı dördüncü modelimiz ise test veri kümesinde %82 gibi bir doğruluk değeri elde etmiştir. F1-skoru ise AH: 0,87; HBB: 0,73 ve KG: 0,86 olarak ölçülmüştür. VGG16 ve karmaşık sınıflandırıcı tabanlı mimarimizin test edildiği beşinci modelimiz ise test kümesi verilerinde %85 oranında yüksek bir doğruluk değeri yakalamıştır. F1-skoru olarak kategorilerde AH: 0,88; HBB: 0,78 ve KG: 0,88 sonuçlarını yakalamıştır. VGG19 mimarili altıncı modelimiz test veri kümesinde %87 oranında iyi bir doğruluk puanı elde etmiştir. F1-skoru olarak ise AH: 0,89; HBB: 0,81 ve KG: 0,89 sonuçlarını yakalamıştır. VGG19 ve sınıflandırıcı tabanlı son mimarimiz ise test verilerinde %93 doğruluk sonucuna ulaşmıştır. Kategorik sınıflandırmada sonuçları bakımından ise F1-skoru incelendiğinde AH: 0,94; HBB: 0,90 ve KG: 0,94 oranlarını yakalamıştır.

VGG19, küçük filtrelerden oluşan derin yapılı bir mimaridir. Bu mimari tasarım, modelin daha lokal ve ayrıntılı özelliklere odaklanmasına yardımcı olur. Bu yeteneğinden dolayı, diğer mimarilere kıyasla daha yüksek doğruluk puanı elde etmiştir. Dolayısıyla, VGG19'un derin ve küçük filtreli yapısı, özellikle ince detayların ve lokal özelliklerin daha iyi öğrenilmesini sağlayarak sınıflandırma performansının artırılmasına yardımcı olmuştur. Bununla birlikte, VGG19'a bağlanan küçük filtrelerden tasarlanan kendi geliştirdiğimiz sınıflandırıcımız, TÖ tabanlı modelden elde edilen özellik haritalarını kullanarak mimarimizin performansını önemli ölçüde artırmıştır. Diğer başarılı modelimiz ise Xception tabanlı modelimizdir.

Xception modeli, diğer yöntemlere göre nispeten daha yeni bir tekniktir. Özellikle ince ayrıntıların önemli olduğu paternlerin analizinde başarılı bir yöntemdir.

Tez kapsamında kullandığımız veri seti dengeli bir dağılıma sahiptir. Bu nedenle modellerimizin elde edeceği doğruluk değerleri yeterli bir performans değerlendirme kriteri olarak kabul edilebilir. Ancak tez kapsamında modellerimizin başarısı tek bir metrikle değerlendirilmemiştir. F1-puanı, duyarlılık ve kesinlik gibi farklı metrikler de kullanılarak modellerin başarısı farklı açılardan doğrulanmıştır. Tez sonuçları, ESA tabanlı yöntemlerin sağlıklı bireyleri ve Alzheimer hastalarını yüksek doğruluk oranlarıyda başarıyla tanımlayabileceğini göstermektedir. Ayrıca, ESA tabanlı yöntemlerin erken tanı için etkili bir karar destek sistemi olarak tercih edilebileceği ortaya konulmuştur. Şekil 4.1.'de tez çalışmasına ait akış diyagramı sunulmaktadır.

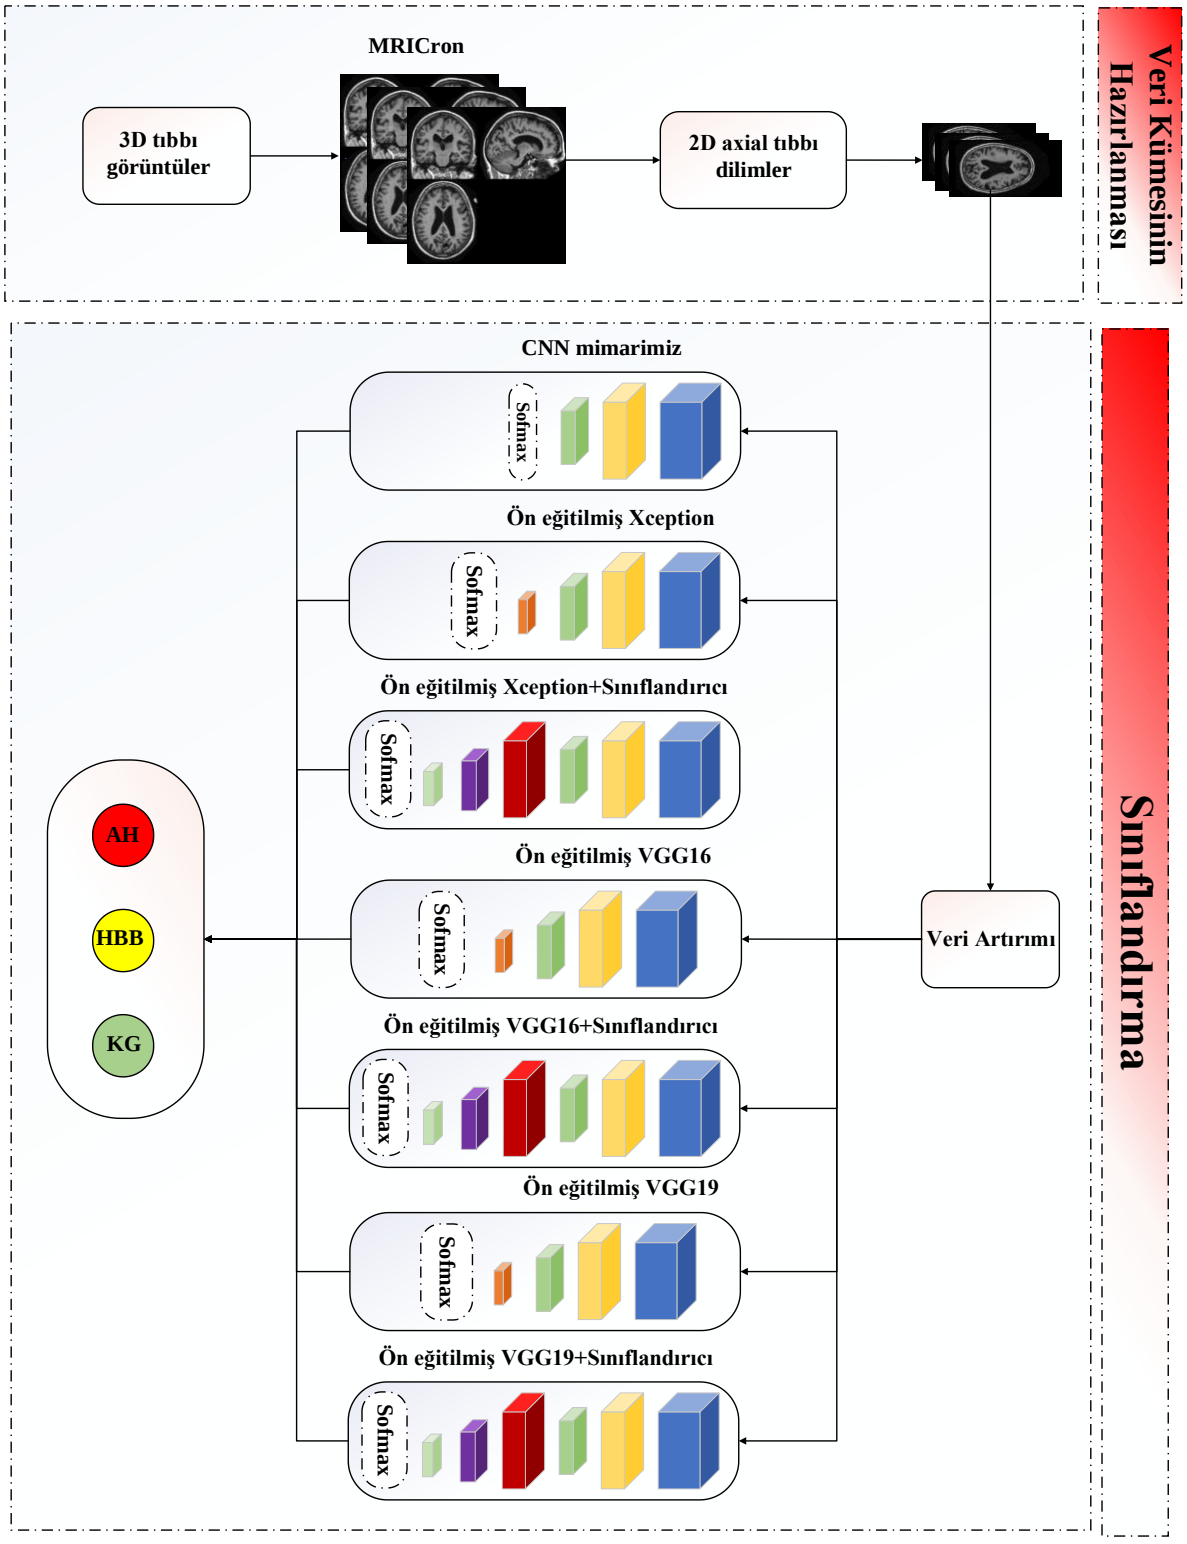


**Şekil 4.1:** AH erken tanısı iş akış grafiği

## 4.1. VERİ KÜMESİ VE ÖN İŞLEME

Bu çalışmada, AH'nin tedavi süreçlerinin incelenmesini sağlayan, hastalık verilerinin analiz edilmesini ve hastalığın iyileştirilmesini aktif olarak teşvik eden dünya çapında bir nöro-araştırma kuruluşu olan OASIS veri tabanından verileri sağladık. OASIS, AH'nin erken teşhisi için araştırmacılara çeşitli şekillerde faydalı olabilecek farklı varyasyonlarda veri setleri sunmaktadır (Marcus ve diğ., 2007). OASIS, standartlaştırılmış veri kümeleri sunarak araştırmacıların birlikte çalışmasına ve uyumlu verileri dünya çapındaki meslektaşlarıyla paylaşmasına imkân tanıyan bir veritabanı sunmaktadır. Bu çalışmada kullanılan veri kümeleri 3B olarak indirilmiştir. Ardından, MRIcron medikal görüntüleme programı yardımıyla 3B beyin taramalarından, beynin AH ile ilgili bölümlerinden alınan kesitler kaydedilmiştir.

### 4.1.1. Veri Kümesi Eldesi

MRIcron, beyin ve diğer organların MRG taramalarını görselleştirmek ve analiz etmek için ücretsiz olarak sunulmuş açık kaynak kodlu bir yazılımdır. Platform bağımsız olarak çalışır. Aynı anda birden fazla görüntü katmanını analiz etmeye imkân tanır. Ayrıca 3B görüntü hacimlerinden ilgilenilen bölge dilimlerinin kaydedilmesine olanak sağlar. MRIcron ile görüntü üzerinde gerçek zamanlı çizimler yapılarak görüntü inceleme işlemleri gerçekleştirilebilir. DICOM gibi görüntüleri NIfTY formatına dönüştürme yeteneğine sahiptir. Tüm bu özellikleri ve yetenekleri sayesinde nörobilimciler, psikologlar, radyologlar ve tıp çalışanları gibi birçok profesyonel tarafından yaygın olarak kullanılmaktadır (Juanes ve diğ., 2016).

Çalışma, OASIS-1 veri kümesi kullanılarak gerçekleştirilmiştir. Veri kümesi toplamda 416 deneğe ait medikal görüntü kümesinden oluşmaktadır. Deneklerin yaşları 18 ile 96 arasında değişmektedir ve hepsi sağ elini kullanmaktadır. Deneklerin 316'sı KG, 70'i HBB ve 30'u ise AH olarak kategorilere ayrılmıştır. Kategorilere ayırma işlemi için Clinical Dementia Rating (CDR) klinik demans değerlendirme ölçeği kullanılmıştır. Bu ölçek, bir bireyin bilişsel ve işlevsel yeteneklerini değerlendirmek için kullanılır. Buna göre, CDR değeri 0 olanlar KG; 0,5 olanlar AH başlangıç evresi olan HBB kategorisinde; 1 ve 2 olanlar ise AH olarak işaretlenmiştir. Tablo 4.1 OASIS-1 veri kümesine ait demografik özellikleri sunmaktadır.

**Tablo 4.1:** OASIS-1 veri tabanı ait demografik özellikler (Fulton ve diğ., 2020).

| Gruplar | KG (CDR=0) | HBB(CDR=0,5) | AH (CDR=1; CDR=2) |
|---|---|---|---|
| Erkek | 119 | 31 | 10 |
| Kadın | 197 | 39 | 20 |
| Toplam | 316 | 70 | 30 |

OASIS-1 veri kümesinden indirilen 3B beyin görüntüleri yardımıyla, AH demansından en çok etkilenen dokulara ait görüntü dilimleri bilgisayar ortamına kaydedilmiştir. ESA tabanlı modellerin eğitimi için 2B aksiyal dilimler tercih edilmiştir. ESA, 3B görüntü dilimlerini başarıyla analiz edebilen ve ilgili özellikleri çıkarabilen bir DÖ yöntemidir. Ancak 3B görüntülerin işlenmesi, 2B görüntülere göre daha fazla işlem gücü gerektirmektedir. Bu ise modellerin eğitim süresini uzatabilmekte ve modellerin eğitimi için gereken donanım ihtiyacını artırabilmektedir. 3B görüntüler yerine sadece hastalıktan etkilenen ilgili bölgelerden alınan 2B görüntülerin kullanılması, ağın eğitim sürecini kısaltabilmektedir (Jianyu ve diğ., 2017). Bu nedenle 2B görüntü dilimleri tercih edilmiştir. Şekil 4.2'de modellerin beslenmesi için kullanılan 2B beyin MR görüntülerine ait örnek dilimler gösterilmektedir.

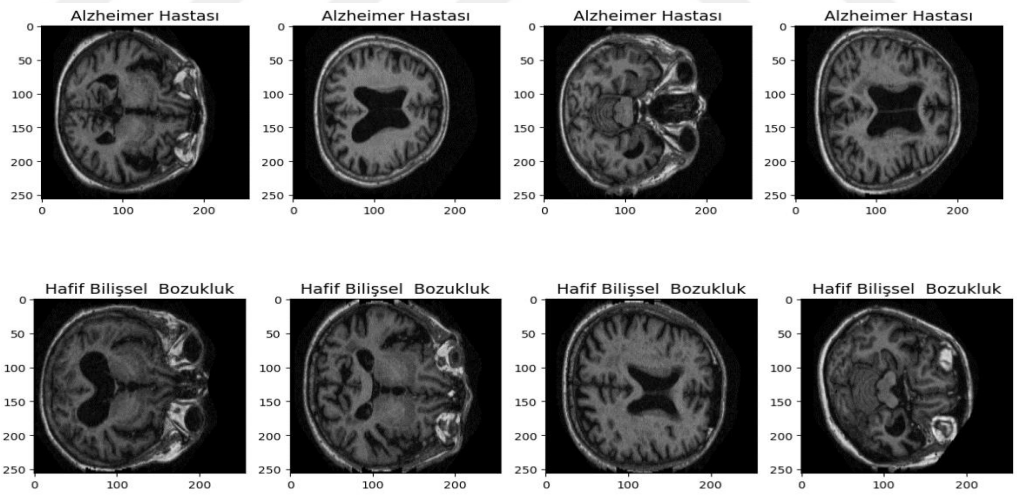

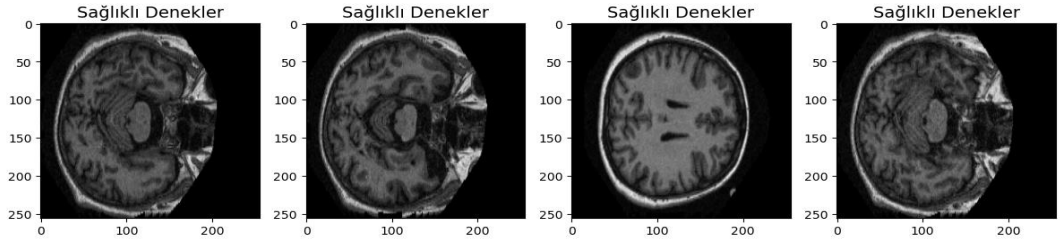


**Şekil 4.2:** Veri kümesine ait örnek görüntü kareleri

3B medikal görüntülerden elde edilen 6.000 adet 2B medikal görüntünün %60'ı eğitim (3.600 adet), %20'si validasyon (1.200 adet) ve kalan %20'si ise modellerin test edilmesi (1.200 adet) amacıyla ayrılmıştır. Çalışma kapsamında kullanılan görüntülere ait istatistiki veri kümesi adedi Tablo 4.2'de sunulmaktadır.

**Tablo 4.2:** Model eğitim/test için kullanılan veri dağılımı

| Veri kümesi | KG | HBB | AH | Toplam tıbbı görüntü adedi |
|---|---|---|---|---|
| Eğitim seti | 1200 | 400 | 400 | 2000 |
| Doğrulama seti | 1200 | 400 | 400 | 2000 |
| Test seti | 1200 | 400 | 400 | 2000 |

### 4.1.2. Veri Artırımı

Veri artırımı, eğitim verilerinin çeşitliliğini ve miktarını yapay olarak artırmak, makine öğrenimi modellerinin performansını ve sağlamlığını iyileştirmek için kullanılır. Mevcut verilerin varyasyonlarını oluşturmak için döndürme, ölçekleme, çevirme ve kırpma gibi teknikleri içerir. Veri artırımı, özellikle temini zor olan kısıtlı veri kümeleri ile yapılan çalışmalarda büyük faydalar sağlar. Bununla birlikte, DÖ modellerinin yetersiz öğrenmesini engellemek için de yararlıdır (Altınkaya ve diğ., 2020). Tez kapsamında modellerin eğitimi esnasında aşağıda tanımlanan veri artırım yöntemlerinden faydalanılmıştır.

- ✓ **Döndürme oranı (20)**: Görüntüleri rastgele 20 dereceye kadar döndürür.
- ✓ **Genişlik kaydırma aralığı (0.1)**: Görüntüleri yatayda rastgele %10 oranında kaydırır.
- ✓ **Yükseklik kaydırma aralığı (0.1)**: Görüntüleri dikeyde rastgele %10 oranında kaydırır.
- ✓ **Yatay çevirme**: Görüntüleri yatayda rastgele olarak ters çevirir.
- ✓ **Dolgu modu (en yakın)**: Dönüşüm sonrası oluşan boş alanları en yakın piksel değerleri ile doldurur.

**Şekil 4.3'te** veri artırım işlemleri sonucunda görüntülerdeki değişimler gösterilmektedir.

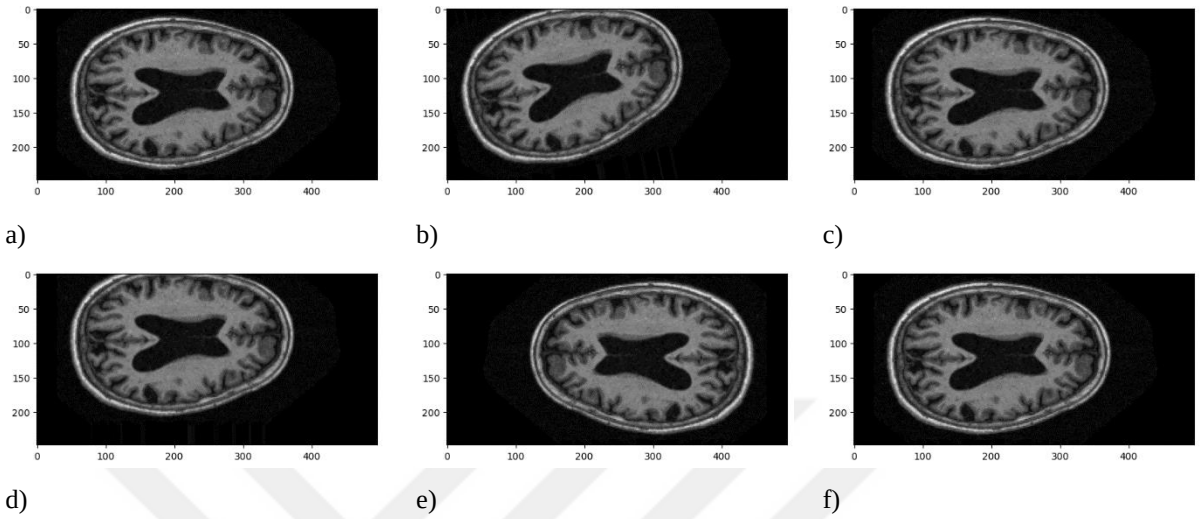


**Şekil 4.3:** Veri artırımı işlemleri a) Orijinal görüntü, b) Döndürme, c) Genişlik kaydırma, d) Yükseklik kaydırma e) Yatay çevirme, f) Dolgu

## 4.2. KULLANILAN YÖNTEM VE MİMARİLER

Modelin beslenmesinde 224x224x3 boyutlarında görüntüler kullanılmıştır. Burada 224x224, görüntünün genişliğini ve yüksekliğini temsil eder. Bu, her bir görüntünün 224 piksel genişliğinde ve 224 piksel yüksekliğinde olacak şekilde modele gönderileceği anlamına gelir. En sondaki 3 ise görüntü derinliğini temsil eder. Yani görüntünün renkli (RGB) olarak modele gönderileceğini belirtir. Birinci modelimizde kendi tasarımımız olan bir mimari önerilmiştir. Diğer altı model ise TÖ tabanlı yöntemlerdir. TÖ, büyük veri kümeleri üzerinde önceden eğitilmiş modellerden yararlanma avantajı sunmaktadır. Böylelikle belirli veri kümeleri üzerinde yeni modellerin eğitilmesi için gereken hesaplama kaynaklarını ve zamanı önemli ölçüde azaltabilmektedir. İlaveten, medikal görüntüler gibi çeşitli protokol ve prosedürler ile edinilebilen, ayrıca uzmanlar tarafından etiketlenme ihtiyacı duyulan verilere erişim zordur. Bu tür verilerin temini zordur. Bununla birlikte kısıtlı sayıda veri kümeleri ile çalışılan DÖ tabanlı yöntemler yetersiz öğrenme sorunları ile karşılaşabilmektedir. TÖ ise önceden eğitilmiş modelden öğrenilen özellikleri yeni göreve aktararak daha iyi performans elde edilmesine imkân verebilmektedir. Tez kapsamında önerilen TÖ yöntemleri, ImageNet

veri kümesi üzerinde önceden eğitilmiş ağırlıkların yüklenmesi ile kullanılmaktadır. ImageNet, bilgisayarla görme algoritmalarını eğitmek ve değerlendirmek için kullanılan popüler bir kaynaktır. ImageNet, büyük ve karmaşık bir veri kümesidir. Ancak iyi organize edilmiş ve kullanımı kolay bir yapıya sahiptir. İstenildiğinde veri kümesi ücretsiz olarak indirilebilir. ImageNet, bilgisayarla görme araştırmaları veya uygulamaları üzerinde çalışan herkes için değerli bir kaynaktır (Deng ve diğ., 2009).

### 4.2.1. Birinci Model: Özgün Mimari

Çalışmamızda ilk olarak AH'nin erken tanısı için özgün olarak tasarladığımız bir DÖ mimarisi test edilmiştir. Spesifik problemler için özel olarak tasarlanmış YZ modelleri başarılı sonuçlar elde edebilmektedir. Özgün mimariler, AH'nin belirli ve spesifik belirtilerine özel olarak uyarlanarak daha yüksek tanı doğruluğu sağlayabilir. Önceden eğitilmiş modeller daha geniş bir görüntü sınıfı üzerinde eğitilmiş olsa da, bazı durumlarda gerekli özellikleri yakalama konusunda daha düşük performans gösterebilirler. Bu doğrultuda tasarlanan mimarimiz, 64 filtre kullanılan, 2x2 çekirdek boyutunda ve same padding işleminden oluşan iki konvüsyon katmanı ile başlamaktadır. Bu katmanları toplu normalleştirme, 2x2 boyutlarında maksimum havuzlama ve 0,25 oranında dropout katmanı takip etmektedir. Mimarinin orta katmanlarında 32 filtreden oluşan, 2x2 çekirdek boyutunda, ReLU aktivasyon fonksiyonlu ve same dolgulu iki konvüsyon katmanı daha bulunmaktadır. Bu katmanları toplu normalleştirme, 2x2 boyutlarında maksimum havuzlama ve 0,25 oranında dropout katmanı takip etmektedir. Bu katmanların ardından yine aynı parametrelere sahip iki konvüsyon, bir toplu normalleştirme, bir maksimum havuzlama ve 0,25 oranında dropout katmanı gelmektedir. Mimarinin son katmanları ise verilerin tek bir vektöre dönüştürülmesini sağlayan düzleştirme katmanı ile başlamaktadır. Bu katmanı, 512 nöronlu ReLU aktivasyon fonksiyonlu bir yoğun katman takip etmektedir. Ardından model ezberlemesini önlemek için 0,5 oranında dropout katmanı gelmektedir. Sınıflandırma işleminin tamamlandığı üç nöronlu ve softmax aktivasyon fonksiyonlu son katmanımız ile modelimiz tamamlanmaktadır. Üçlü bir sınıflandırma işlemi yapıldığından son katman üç nörondan oluşmaktadır. AH erken tanısı için geliştirilen birinci modelimizin mimari ayrıntıları Tablo 4.3'te gösterilmektedir.

**Tablo 4.3:** Birinci mimarimiz

| **Katman** | **Çıktı şekli** | **Parametre** |
|---|---|---|
| Konvolüsyon | (224, 224, 64) | 832 |
| Konvolüsyon | (224, 224, 64) | 16,448 |
| Toplu_normalleştirme | (224, 224, 64) | 256 |
| Maksimum havuzlama | (112, 112, 64) | 0 |
| Dropout | (112, 112, 64) | 0 |
| Konvolüsyon | (112, 112, 32) | 8,224 |
| Konvolüsyon | (112, 112, 32) | 4,128 |
| Toplu_normalleştirme | (112, 112, 32) | 128 |
| Maksimum havuzlama | (56, 56, 32) | 0 |
| Dropout | (56, 56, 32) | 0 |
| Konvolüsyon | (56, 56, 32) | 4,128 |
| Konvolüsyon | (56, 56, 32) | 4,128 |
| Maksimum havuzlama | (28, 28, 32) | 0 |
| Dropout | (28, 28, 32) | 0 |
| Konvolüsyon | (28, 28, 32) | 4,128 |
| Konvolüsyon | (28, 28, 32) | 4,128 |
| Maksimum havuzlama | (14, 14, 32) | 0 |
| Dropout | (14, 14, 32) | 0 |
| Düzleştirme | (1568) | 0 |
| Yoğun | (512) | 3,211,776 |
| Dropout | (512) | 0 |
| Yoğun | (3) | 1,539 |
| Toplam parametre | | 3,259,843 |

DÖ tabanlı mimariler genellikle karmaşık ve anlaşılması zor katmanlardan oluşur. Bu durum, mimarinin anlaşılmasını zorlaştırabilir. Ancak ağ tasarımını görsel olarak sunmak için çeşitli kütüphaneler geliştirilmiştir. Bu kütüphaneler arasında Visualkeras öne çıkar; özel olarak tasarlanmış bir Python kütüphanesidir ve tasarlanan bir sinir ağı mimarisini görselleştirmek için kullanılır. Visualkeras ağ model mimarisinin daha net bir görsel temsilini sağlayarak DÖ modellerinin performansını anlamaya, hata ayıklamaya ve potansiyel olarak iyileştirilmesine yardımcı olabilir (Gavrikov ve diğ., 2020). Şekil 4.4'te birinci modele ait ağ tasarım mimarisi sunulmaktadır.

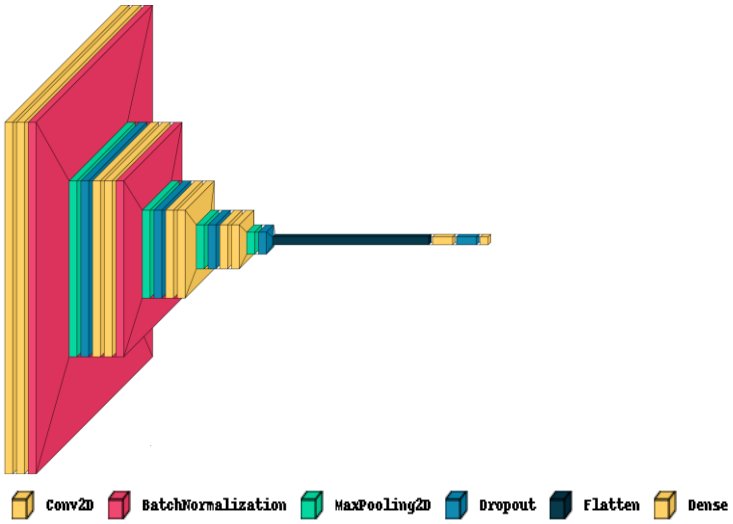


**Şekil 4.4:** Birinci mimarimizin ağ blok tasarımı

### 4.2.2. İkinci Model: Xception

İkinci model olarak özellikle yerel minimum değişiklikleri yakalamada başarılı olduğu bilinen bir DÖ mimarisi olan Xception tercih edilmiştir. Xception, derin konvolüsyonel katmanları ve daha küçük ölçeklerde özellik seçimi yeteneğiyle bilinmektedir. Bu model, çeşitli görüntü işleme ve sınıflandırma problemlerinde iyi performansa sahip bir mimari olarak karşımıza çıkmaktadır. Tezde, AH erken tanısı gibi küçük minimal değişikliklerden kaynaklı görüntü analizleri çözümünde Xception tabanlı DÖ yöntemi bu özelliği için seçilmiştir. Bu yöntemde, Xception tabanlı TÖ yöntemi özellik çıkarıcı olarak kullanılmaktadır. Ön eğitilmiş model, ESA'nın otomatik özellik çıkarım yeteneğini kullanmaktadır. ImageNet veri kümesinde eğitilmiş Xception mimarisinin tam bağlı katmanları hariç tutularak son katmanı yeniden tasarlanmıştır. Bunun için konvolüsyonel katmanlar dondurulmaktadır. İkinci yöntemde, evrişimsel katmanların yeniden eğitilmesini önlemek ve önceden eğitilmiş ağırlıkları korumak için Xception modelindeki her katman bir döngü yardımıyla taranmış ve eğitilebilir öznitelikler kapalı olarak ayarlanmıştır. Ardından, sınıflandırma işlemi için TÖ modelinin son evrişimsel katmanından gelen çok boyutlu özellik haritaları tek boyutlu bir diziye dönüştürülerek basit bir mimari olarak tasarlanmış sınıflandırıcının girişi için hazırlanmıştır. Düzleştirme işleminden sonra aşırı uyumu önlemek için eğitim sırasında nöronlara %10 oranında dropout işlemi uygulanmıştır. En son katman olan çıktı katmanı ise üç sınıfa karşılık gelen bir yoğun katman ile tamamlanmaktadır. Bu katman, her sınıf için olasılıklarını çıkaran bir softmax aktivasyon fonksiyonu içermektedir. Tablo 4.4, ikinci modelin mimarisini

sunmaktadır. Tabloda Xception modeline ait çıktı ve parametre bilgilerinin eklenmesine gerek duyulmamıştır. Doğrudan kullanılan basit sınıflandırıcı mimarisinin gösterilmesi yeterli görülmüştür.

**Tablo 4.4:** Xception modeli mimarisi

| **Katman** | **Çıktı şekli** | **Parametre** |
|---|---|---|
| Xception Modeli (Özellik seçici) | | |
| Düzleştirme | (100352) | 0 |
| Dropout | (512) | 0 |
| Yoğun | (3) | 301,059 |
| Toplam parametre | | 21,162,539 |

Xception, çok sayıda katmandan oluşan bir mimaridir. Şekil 4.5'te ikinci modele ait ağ tasarımı sunulmaktadır.

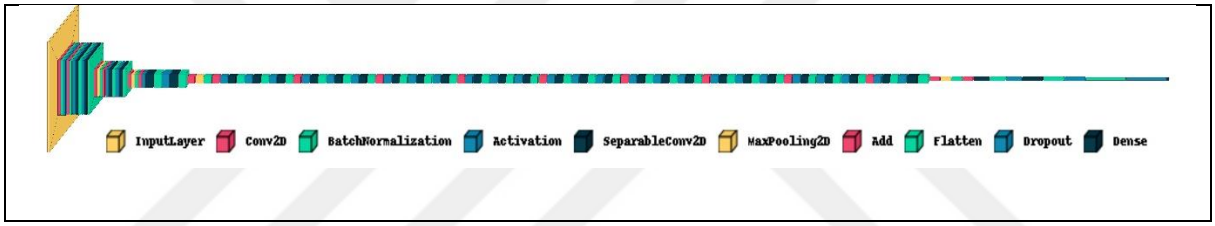


**Şekil 4.5:** İkinci mimarimizin ağ blok tasarımı

### 4.2.3. Üçüncü Model: Xception + Sınıflandırıcı

Üçüncü model olarak yine Xception tabanlı bir yöntem kullanılmıştır. Ancak bu modelde ikinci modelden farklı olarak TÖ modeli daha karmaşık bir sınıflandırıcı yapısı ile tamamlanmıştır. Bunu gerçekleştirmek için modele daha fazla katman eklenmiştir. Bu katmanlar modelin daha fazla parametreye sahip olmasını sağlamaktadır. Dolayısıyla ek katmanlar, modelin daha karmaşık veri ilişkilerini öğrenebileceği anlamına gelmektedir. Bu ise ek katmanlardan kaynaklı olarak mimarimizin daha uzun eğitim sürelerine ve daha yüksek hesaplama maliyetlerine ihtiyaç duyacağı anlamına gelmektedir. Ancak bu çalışmada ana odak noktamız, yüksek doğruluk oranına sahip ve karmaşık özellik ilişkilerini başarılı bir şekilde öğrenebilen bir model geliştirmektir. Tasarlanan mimarimizde Xception modelimizin evrişimsel katmanlarının yeniden eğitilmesi engellenmektedir. TÖ tabanlı modelimiz, görüntülerden ilgili özellik haritalarını çıkarmak amacıyla kullanılmaktadır. Daha sonra özellik haritaları düzleştirme işlemi ile sınıflandırıcı modelimize gönderilmek için tek boyutlu

diziye çevrilmektedir. Sınıflandırıcımız, toplu normalizasyon katmanı ile başlamaktadır. Devamında 512 nörondan ve ReLU aktivasyon fonksiyonundan oluşan bir yoğun katman gelmektedir. Ardından bir toplu normalizasyon katmanı bulunmaktadır. Bu katmanın ardından ezber öğrenmeyi engellemek için %20 oranında dropout işlemi yapılmaktadır. Bu işlemi 256 nörondan ve ReLU aktivasyon fonksiyonundan oluşan bir yoğun katman takip etmektedir. Ardından toplu normalizasyon ve %20 oranında dropout işlemleri gelmektedir. Sınıflandırıcımız, 128 nörondan ve ReLU aktivasyon fonksiyonundan oluşan bir yoğun katman ile devam etmektedir. Bu katmanı yine toplu normalizasyon ve %20 oranında dropout işlemleri takip etmektedir. Sınıflandırıcının son katmanlarına doğru 64 nörondan ve ReLU aktivasyon fonksiyonundan oluşan bir yoğun katman yer almaktadır. Bu katmanın ardından toplu normalizasyon ve %20 oranında dropout işlemleri uygulanmaktadır. Sinir ağı sınıflandırıcısının son katmanı, üç sınıflı bir çıkış üretmektedir. Bu katman, softmax aktivasyonunu kullanarak her sınıf için bir olasılık değeri hesaplamaktadır. Tablo 4.5, üçüncü modele eklenen karmaşık sınıflandırıcı mimarisinin ayrıntılarını sunmaktadır. Tabloda Xception modeline ait çıktı ve parametre bilgileri eklenmemiştir. Doğrudan sınıflandırıcı mimarisi gösterilmektedir.

**Tablo 4.5:** İkinci mimarimizin ağ blok tasarımı

| **Katman** | **Çıktı şekli** | **Parametre** |
|---|---|---|
| **Xception Modeli (Özellik Çıkarıcı)** | | |
| Düzleştirme | (100352) | 0 |
| Toplu normalleştirme | (100352) | 401,408 |
| Yoğun | (512) | 51,380,736 |
| Toplu normalleştirme | (512) | 2,048 |
| Dropout | (512) | 0 |
| Yoğun | (256) | 131,328 |
| Toplu normalleştirme | (256) | 1,024 |
| Dropout | (256) | 0 |
| Yoğun | (128) | 32,896 |
| Toplu normalleştirme | (128) | 512 |
| Dropout | (128) | 0 |
| Yoğun | (64) | 8,256 |
| Dropout | (64) | 0 |
| Toplu normalleştirme | 64 | 256 |
| Yoğun | (3) | 195 |
| Toplam parametre | | 72,820,139 |

Şekil 4.6'da üçüncü modelimize ait ağ tasarım mimarisi sunulmaktadır. Bu modelimizde yüksek bir sınıflandırma performansı elde edilmiştir.

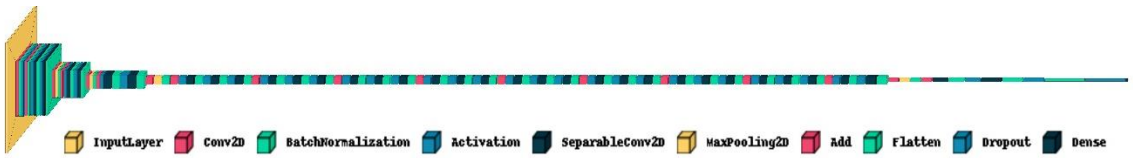


**Şekil 4.6:** Üçüncü mimarimizin ağ blok tasarımı

### 4.2.4. Dördüncü Model: VGG16

Tez kapsamında dördüncü model olarak VGG16 modeli test edilmiştir. VGG16 mimarisinin diğer modellere kıyasla çeşitli avantajları vardır. VGG16 mimarisi, tüm ağ tasarımı boyunca küçük 3x3 konvolüsyon filtrelerini kullanır. Ayrıca, diğer modellere kıyasla nispeten daha basit bir mimari tasarımına sahiptir. Böyle basit bir mimari, modelin uygulanmasını kolaylaştırır. Basitliğine rağmen, karmaşık özellikleri etkili bir şekilde yakalamasını sağlayan 16 katmanlı bir yapıya sahiptir. VGG16, çeşitli görevlerde iyi başarılar elde etmiş bir modeldir. ImageNet Large Scale Visual Recognition Challenge (ILSVRC) yarışmasında 2014'te en iyi sonucu elde etmiştir. Bu başarısı, VGG16 mimarisini AH tanısı ve HBB erken evre teşhisi çalışmamız için kullanılabilecek bir model olarak karşımıza çıkarmıştır (Nana Hermana ve diğ., 2021). Ayrıca, VGG16 önceki katmanlarda öğrenilen özellikleri (kenarlar, dokular ve basit şekiller vb.) yüksek oranda genelleştirebilir. VGG16 bu yeteneği sayesinde özellikle test edilebilir ve etkili olabilecek bir modeldir. Tüm bu başarılarından dolayı, farklı veri kümelerinin denenebileceği yeni görevlerde tercih edilebilecek bir model olarak öne çıkmaktadır (Attallah, 2023). Bu modelde de mimarinin eğitilebilir katmanları dondurulmuştur. Ardından, tez kapsamında tasarlanan ve basit yapısı ikinci model ile açıklanan sınıflandırıcı kullanılarak geliştirilen beşinci model sonlanmaktadır. Tablo 4.4'te basit tasarım sınıflandırıcıya ait mimari sunulmuştur. Şekil 4.7'de ise dördüncü modelde kullanılan mimari tasarımımız sunulmaktadır.

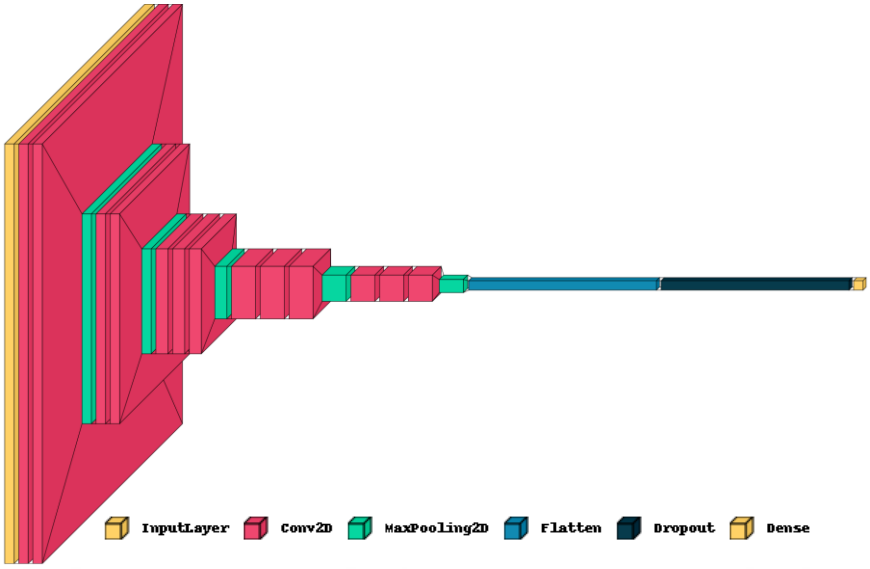


**Şekil 4.7:** Dördüncü mimarimizin ağ blok tasarımı

### 4.2.5. Beşinci Model: VGG16 + Sınıflandırıcı

Tez için test edilen beşinci modelimizde yine VGG16 tabanlı bir yöntem test edilmiştir. Ancak bu model üçüncü modelimizde kullandığımız karmaşık sınıflandırıcı modelimizle tamamlanmıştır. Bu şekilde VGG16 tabanlı ön eğitilmiş modelimizin performansının artırılması hedeflenmiştir. Dördüncü modelimizde farklı olarak, karmaşık sınıflandırıcı tasarımımızda bulunan düzenleme ve normalleştirme işlemleri ile modelin genel derinliği ve karmaşıklığı artırılmaya çalışılmıştır. Bu katmanların eklenmesiyle özellikle karmaşık ve çeşitli veri örüntülerinden öğrenme gerektiren görevler için dördüncü modele kıyasla daha sağlam ve potansiyel olarak daha yüksek performanslı bir model elde edilmesi amaçlanmıştır. Eklenen sınıflandırıcı mimarisi Tablo 4.5'te sunulmakta olup, beşinci modelin mimari ayrıntıları Şekil 4.8'de sunulmaktadır.

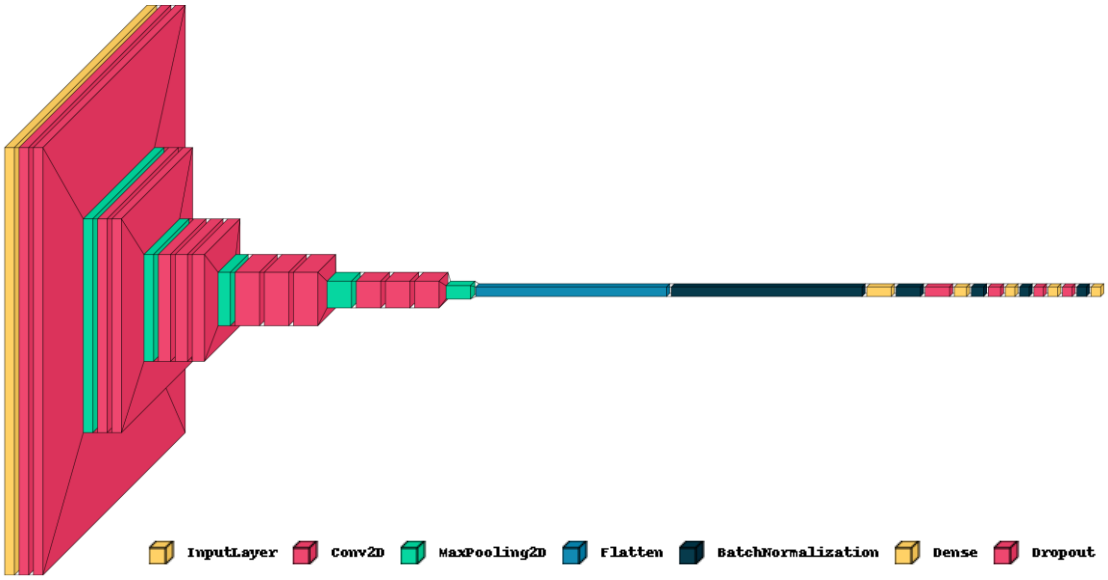


**Şekil 4.8:** Beşinci mimarimizin ağ blok tasarımı

### 4.2.6. Altıncı Model: VGG19

Altıncı mimari olarak VGG19 modeli denenmiştir. Bu modelin eğitilebilir katmanları dondurulmuştur. Bu model, birçok yöntem arasında avantajlı bir yöntem olarak karşımıza çıkmaktadır. İlk olarak, VGG19 modeli, VGG16 modeline göre daha derin bir mimariden oluşmaktadır. VGG19 mimarisi 19 katmana sahiptir. Ek katmanlar, VGG19'un daha karmaşık ve ayrıntılı özellikleri öğrenmesine olanak tanıyarak daha zorlu görevlerde daha iyi performans göstermesini sağlamaktadır. Ekstra eklenmiş katmanlar, giriş verilerinden daha ince ayrıntıların ve daha karmaşık desenlerin yakalanmasına yardımcı olmaktadır. VGG19, daha derin mimarisi ile daha derin ve daha soyut özellikler çıkarabilir. Bu, TÖ tabanlı yöntemlerin tecrübe edildiği görevlerde daha yüksek düzeyde özellik çıkarma işlemlerinde faydalı olabilir. Daha derin bir mimari modelde daha karmaşık özellik haritaları elde edilmesine imkân sağlamaktadır. Böylelikle, verilerdeki ince farklılıkları içeren görevlerde performans artışı sağlanabilmektedir. Bununla birlikte, literatürde yapılan çeşitli çalışmalar, VGG19'un belirli görevlerde VGG16'ya kıyasla daha etkili bir yöntem olabileceğini göstermiştir (Rajab ve diğ., 2024). Bu nedenlerden dolayı, tez kapsamında altıncı model olarak VGG19 denemiştir. Bu TÖ modeli, Tablo 4.4'te mimarisi sunulan basit model sınıflandırıcımız kullanılarak sınıflandırma işlemini gerçekleştirmektedir. Şekil 4.9'da altıncı modele ait ağ tasarım mimarisi sunulmaktadır.

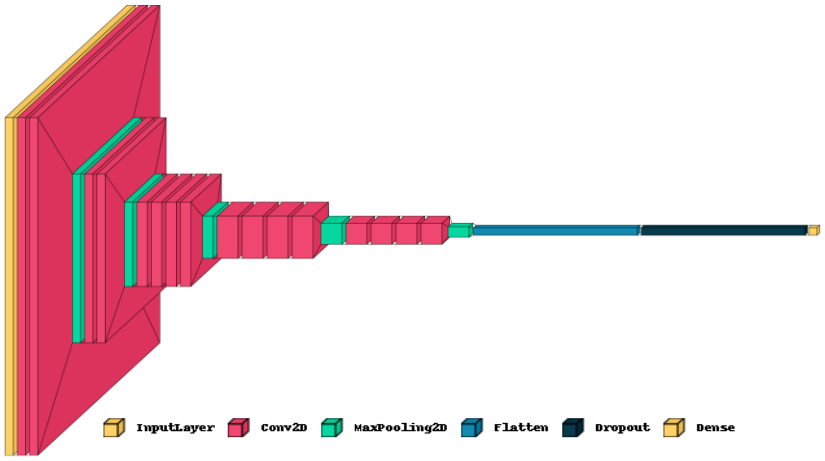


**Şekil 4.9:** Altıncı mimarimizin ağ blok tasarımı

### 4.2.7. Yedinci Model: VGG19 +Sınıflandırıcı

Tez kapsamında son model olarak VGG19 tabanlı modelimiz karmaşık sınıflandırıcı mimarimize bağlanmıştır. İlk olarak modelin eğitilebilir katmanları dondurulmuştur. Ardından VGG19 modelimize özel katmanlar eklenerek modelimizin genelleme yeteneğini geliştirmek ve belirli sınıflandırma görevlerine göre uyarlanmış bir mimari ortaya çıkarmak amaçlanmıştır. Özellik çıkarma için önceden eğitilmiş evrişimli katmanlar kullanılmıştır. Göreve özgü öğrenme için eklenen katmanlar ile daha etkili ve uyarlanabilir bir model elde edilmesi amaçlanmıştır. Eklenen karmaşık sınıflandırıcı modelimize ait ayrıntılı mimari Tablo 4.5'te gösterilmiştir. Şekil 4.10 ise son modelimizin mimari tasarımını göstermektedir.

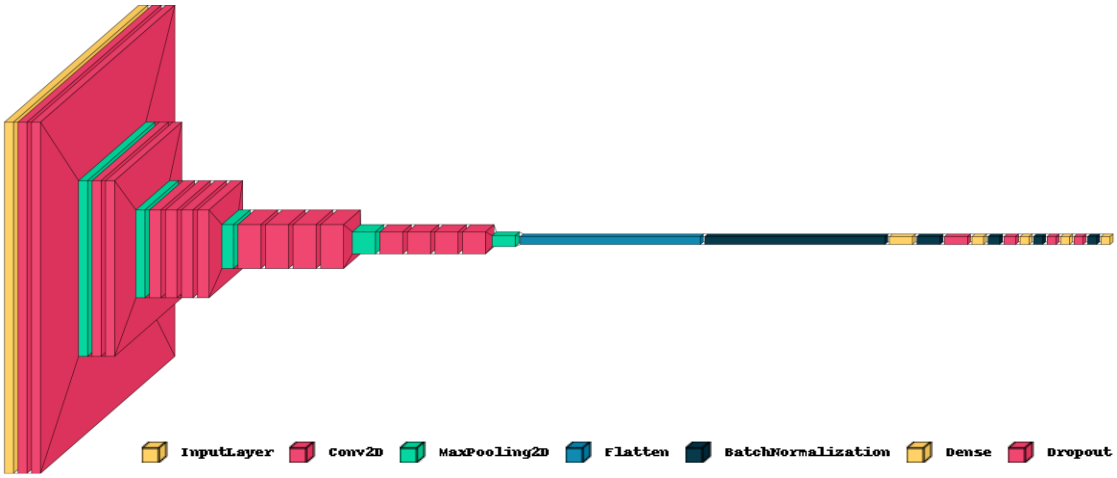


**Şekil 4.10:** Yedinci mimarimizin ağ blok tasarımı

## 4.3. SONUÇLAR VE TARTIŞMA

Bu bölümde, modellerin test ortamını tanıttıktan sonra, tez kapsamında test edilen yedi farklı mimariye ait sonuçları açıklamaktayız.

### 4.3.1. Deneysel Ayarlar

YZ birçok alanda başarıyla uygulanmaktadır. YZ uygulamaları geliştirmek için birçok yazılım dili ve geliştirme ortamı bulunmaktadır. Ancak bu diller arasında Python, şu anda YZ ve MÖ için kullanılan en popüler programlama dillerinden biri olarak karşımıza çıkmaktadır. Bunun nedeni, Python'un çok geniş bir kütüphane desteğine sahip olmasıdır. Python dilinde bulunan TensorFlow, NumPy, Pandas ve Matplotlib gibi kütüphaneler, YZ geliştiricilerin işini kolaylaştırmaktadır. Pandas ve NumPy kütüphaneleri, MÖ algoritmalarımızı verilerle beslemeden önce onları keşfetmenize, temizlemenize ve dönüştürmenize olanak sağlar. Matplotlib kütüphanesi, değerlerimizi ve sonuçlarımızı görselleştirme açısından fayda sağlar. TensorFlow kütüphanesi, MÖ için tasarlanmış güçlü ve açık kaynaklı bir kütüphanedir. Scikit-learn kütüphanesi ise çeşitli MÖ problemleri için çok çeşitli algoritmalar ve araçlar sağlar. Test ortamına ilk olarak Anaconda geliştirme ortamı kuruldu. Anaconda yazılımı, içerisinde çeşitli yazılım geliştirme araçları barındırır. Bunlardan birisi olan Jupyter Notebook, veri bilimi, yapay zeka ve çeşitli alanlarda kullanılan etkileşimli bir yazılım geliştirme ortamıdır. Hem bir not defteri hem de yazılım geliştirme ortamı sağlar. Böylelikle kodlarınızı yazmanıza ve çalıştırmanıza imkân sağlarken, aynı ortamda gerekli açıklamaları da kullanabilmenize olanak sunar. Tezdeki modellerin hepsi Python 3.12.1 versiyonu kullanılarak, TensorFlow 2.15.0 ve Keras 2.15.0 kütüphane sürümleri ile gerçekleştirilmiştir. Test ortamı, Windows 11 64 bit işletim sistemi yüklü bir bilgisayarda çalıştırıldı. Bilgisayar 2.7 GHz hızında Intel Core i7-7500U işlemciye ve 2 GB GDDR5 belleğe sahip NVIDIA GeForce 940MX ekran kartına sahiptir. Sistemde ayrıca 8 GB DDR5 RAM bulunmaktadır.

### 4.3.2. Hiperparametre Ayarları ve Optimizasyon

Tez çalışmamızda yedi farklı model kullanarak çoklu tahmin işlemi gerçekleştirmeye çalıştık. Orijinal kaydettiğimiz veri kümesindeki görüntüler 496x248x3 boyutlarındaydı. Çalışmamızda ise veri kümelerimizi 224x224x3 boyutlarına çevirerek modelleri besledik. Bu boyutları tercih etmemizin sebebi, TÖ tabanlı modellerimizin ImageNet veri kümesinde bu boyutlarla eğitilmiş olmasıydı. Böylece modellerimizin aşina olduğu bir boyut türünü tercih ettik. Tüm modellerin performans kıyaslamasını eşit şartlarda yapmak için öğrenme katsayısı

başlangıç değeri olarak 0.0005 seçilmiştir. Bu değeri seçerken daha küçük ve daha büyük değerlerle modelleri test ettik. Sonuçta en iyi sonucu bu başlangıç değerinde elde ettik. Ancak bu değerin modelin eğitim sonucuna göre optimize edilmesi için Uyarlanabilir Moment Tahmini (Adam optimizer) kullandık. Adam optimizer yardımıyla öğrenme parametrelerimizin otomatik olarak iyileştirilmesini sağladık. Modellerin eşit şartlarda analiz edilebilmesi için her bir model 50 epoch boyunca eğitildi. Bu sayede her model için eşit parametreler kullanılarak en başarılı sınıflandırıcı modeli bulmaya çalıştık. Çalışmamızda HBB evresini de tahmin etmeye çalışacağımızdan dolayı, bu işlemi bir çoklu sınıflandırma problemi olarak kabul ettik. Bu nedenle modellerimiz ikiden fazla kategoriye ait çıktı verecektir. Bu bağlamda kayıp fonksiyonu olarak "Kategorik Çapraz Entropi" ve doğruluk fonksiyonu olarak "Kategorik Doğruluk" seçildi. Modellerin eğitiminde kullanılan veri setimiz dengeli bir yapıya sahiptir. Dolayısıyla doğruluk (accuracy) değeri dengeli veri setlerinde yeterli görülebilmektedir. Ancak çalışmamızda modellerimizin başarısını diğer metriklerle de test ettik. Bu sayede çalışmamızı daha ayrıntılı inceleme imkânı elde ettik ve sonuçlarımızı birçok açıdan değerlendirmiş olduk. Tablo 4.6'da modellerin tasarımında kullanılan ortak hiperparametreler gösterilmektedir.

**Tablo 4.6:** Modellerde kullanılan hiper parametreler

| **Kayıp fonksiyonu** | **Adım sayısı (epoch)** | **Yeniden ölçeklendirme** | **Öğrenme oranı** | **Yığın boyutu** | **Optimize edici** | **Metrik** |
|---|---|---|---|---|---|---|
| Kategorik çapraz entropi | 50 | 1/.255 | 0.0005 | 32 | Uyarlanabilir Moment Tahmini | Doğruluk |

# 5. TARTIŞMA

Birçok değerlendirme metriğine göre üçüncü ve yedinci modellerimiz olan Xception ve VGG19 tabanlı yöntemlerimiz, diğer modellere kıyasla en başarılı modeller olarak görülmüştür. Xception tabanlı yöntemimiz derin bir mimari tasarımdır ve daha az parametre ile çalışır. Bu tasarım, modelin daha karmaşık özellikleri öğrenebilmesini sağlar. Bu sayede AH ile ilgili gerekli özellikleri başarıyla kavrayabilmiştir. Diğer bir başarılı modelimiz VGG19 modelidir. VGG19 modeli, başarılı bir sınıflandırma modelidir. Özellikle derin katmanlı mimarisi karmaşık örüntülerden ince ayrıntılar yakalamasına büyük fayda sağlamaktadır. Çalışmada bu modeli daha da iyileştirmeye çalıştık. Ayrıca, modelimizi iyileştirmek için geliştirdiğimiz sınıflandırıcımız, VGG19 modeli ile birlikte yüksek performansını elde etmiştir. Sınıflandırıcımızı tasarlarken kullandığımız küçük filtreler, modelin sınıflandırma performansını artırırken, dropout katmanları aşırı ezberlemeyi önlemiştir. Tezde test edilen modellerin eğitimlerini incelediğimizde; birinci modelimiz olan özgün tasarımımız, eğitim veri setinde %78 doğruluk ve 0,538 kayıp skoru elde etmiştir. Modelde 15. adımdan sonra çok fazla iyileşme gerçekleşmediği görülmektedir. Modelde eğitim doğruluğu zamanla artarken, doğrulama doğruluğu düzenli olarak artamamaktadır. Bu ise modelimizin eğitim verilerinde genelleme yeteneğinin daha fazla ilerlemediğini göstermektedir. Sonuçları genel olarak değerlendirdiğimizde, birinci modelimizin eğitim ve kayıp performans sonuçları diğer modellere göre başarısız kalmıştır. Özgün tasarımımız olan birinci modelimizde küçük çekirdek filtreli katmanlar kullanarak bir mimari tasarım yaptık. Buna rağmen modelimizde eğitim veri setinde doğruluk puanının 0.8'in altında kaldığı görülmektedir (Şekil 5.1).

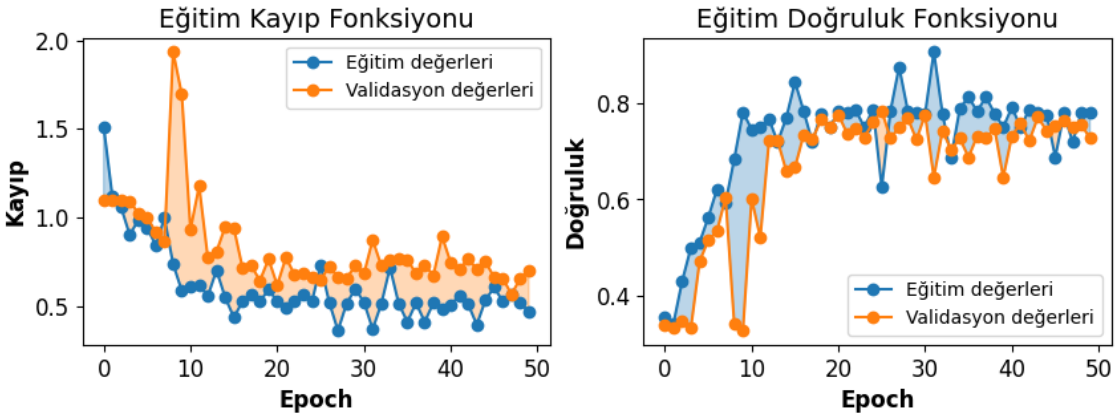


**Şekil 5.1:** Birinci modelimizin eğitim ve kayıp fonksiyon grafikleri

Tezdeki diğer modeller TÖ tabanlı yöntemlerdir. TÖ tabanlı diğer modeller, gelişmiş özellik çıkarıcı yetenekleri sayesinde birinci modelimizden daha iyi sonuçlar elde ettiği görülmüştür. Xception tabanlı ikinci modelimizin performans sonuçları ise birinci yöntemimize göre oldukça iyidir. İyileşme, TÖ'nün sağladığı genelleme yeteneğinden kaynaklanmaktadır. İkinci modelimiz, eğitim veri setinde %92 doğruluk ve 0.201 kayıp skoru elde etti. Model eğitimi analiz ettiğimizde, ilk epochlarda öğrenmenin çok hızlı olduğu görülmektedir. Sonrasında modelin genelleme yeteneğinin fazla iyileşmediği anlaşılmaktadır (Şekil 5.2).

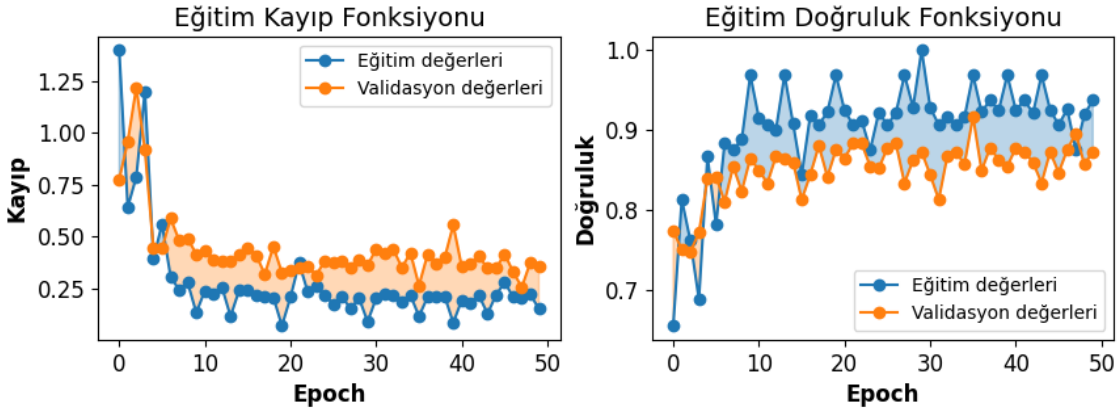


**Şekil 5.2:** İkinci modelimizin eğitim ve kayıp fonksiyon grafikleri

Üçüncü modelimiz, ikinci modelimize önerdiğimiz sınıflandırıcının eklenmesiyle tasarlanmıştır. Sınıflandırıcımızın eklenmesi, modelin eğitim ve validasyon performansını iyileştirmiştir. Özellikle eğitim ve validasyon arasındaki farkın kapandığı grafiklerde bu

durum anlaşılmaktadır. Üçüncü modelimiz, %96 doğruluk ve 0.114 kayıp skorunu eğitim setinden elde etmiştir (Şekil 5.3).

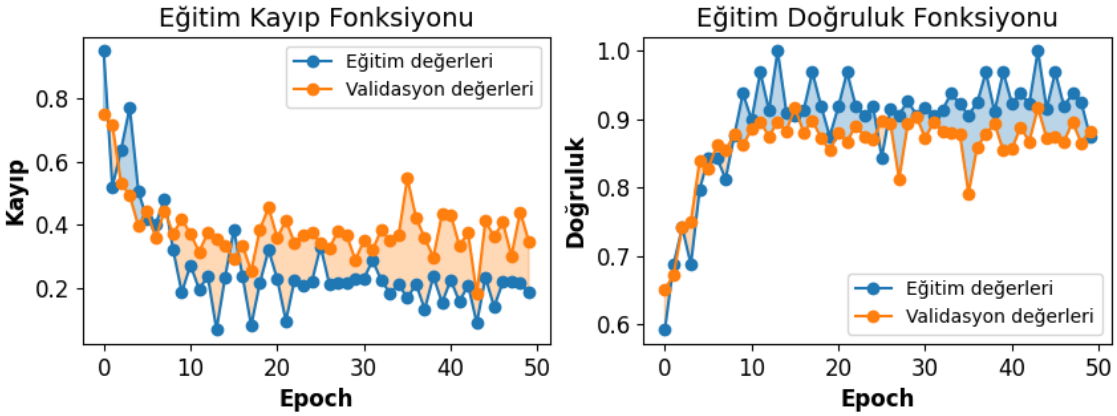


**Şekil 5.3:** Üçüncü modelimizin eğitim ve kayıp fonksiyon grafikleri

VGG16 tabanlı dördüncü yöntemimizin performansı diğer TÖ modellerine göre nispeten düşük kalmıştır. Özellikle validasyon ve eğitim sonuçları arasındaki kayıp değerleri, modelimizin diğer TÖ tabanlı yöntemlere göre daha başarısız bir eğitim geçirdiğini göstermektedir. Modelimiz test kümesinden %87 doğruluk ve 0.39 kayıp skoru elde etti (Şekil 5.4).

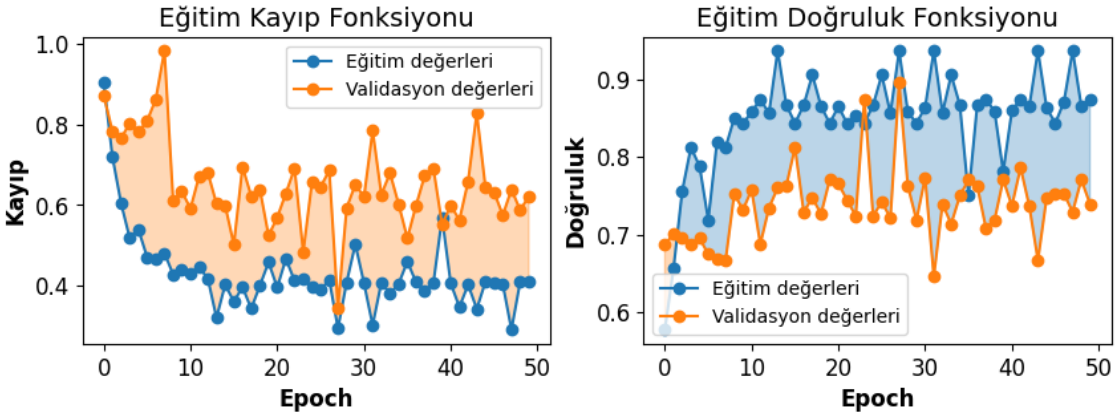


**Şekil 5.4:** Dördüncü modelimizin eğitim ve kayıp fonksiyon grafikleri

VGG16 modelimize, tez kapsamında geliştirdiğimiz sınıflandırıcımızın eklenmesiyle tasarladığımız beşinci modelimizde ise dördüncü modele göre kısmen iyileşme olduğu görülmektedir. Burada eklenen sınıflandırıcımızın başarısından bahsedebiliriz.

Sınıflandırıcımız, VGG16 modelinin performansını artırmıştır. Beşinci modelimiz eğitim verileri üzerinde %90 doğruluk ve 0.270 kayıp skoru elde etmiştir (Şekil 5.5).

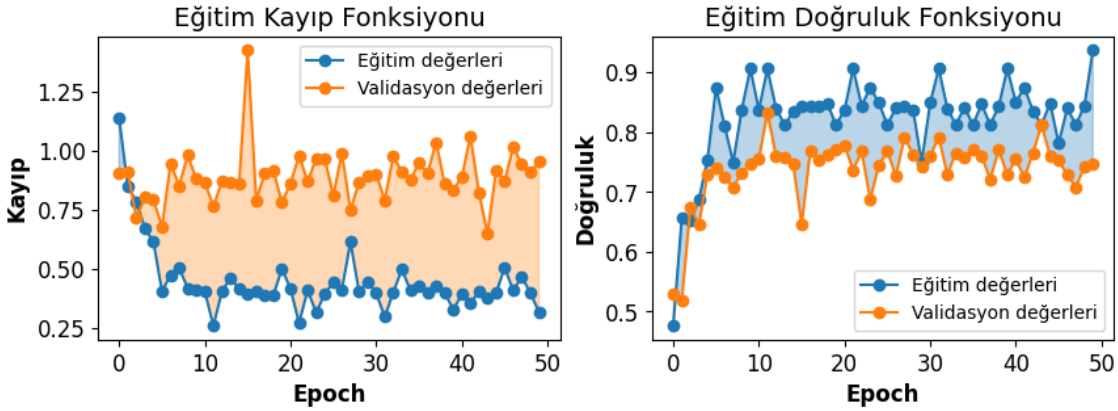


**Şekil 5.5:** Beşinci modelimizin eğitim ve kayıp fonksiyon grafikleri

Tez kapsamında test edilen altıncı modelimiz VGG19 tabanlı bir TÖ modelidir. VGG19 tabanlı modelimiz, VGG16 tabanlı modelimize göre daha iyi performans göstermiştir. Modelimiz %92 doğruluk ve 0.317 kayıp skoru elde etmiştir. Bunu, VGG16 modeline göre daha fazla katmandan oluşan mimarisi sağlamıştır (Şekil 5.6).

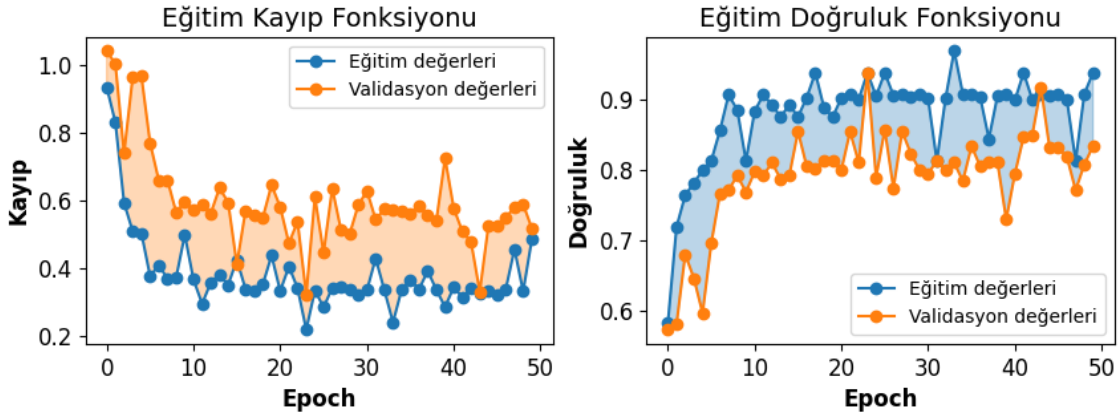


**Şekil 5.6:** Altıncı modelimizin eğitim ve kayıp fonksiyon grafikleri

Yedinci modelimiz, altıncı modelimize kıyasla daha fazla toplu normalleştirme, yoğun katman ve nörona sahiptir. Bu katmanlar, önerdiğimiz sınıflandırıcının kullanılmasıyla oluşmuştur. Bu katmanlar, modelin daha karmaşık özellikler öğrenmesine yardımcı olmuştur. Ayrıca, bu katmanlar önerilen modelimizin daha iyi genelleme yapmasını sağlamıştır. Bu sayede, diğer tüm modellere kıyasla en iyi eğitim puanı sonuçlarını elde etmiştir. %98

doğruluk ve 0.072 kayıp skorunu elde eden yedinci modelimiz kapsamında test edilen en başarılı modellerden biri olduğu anlaşılmıştır (Şekil 5.7).

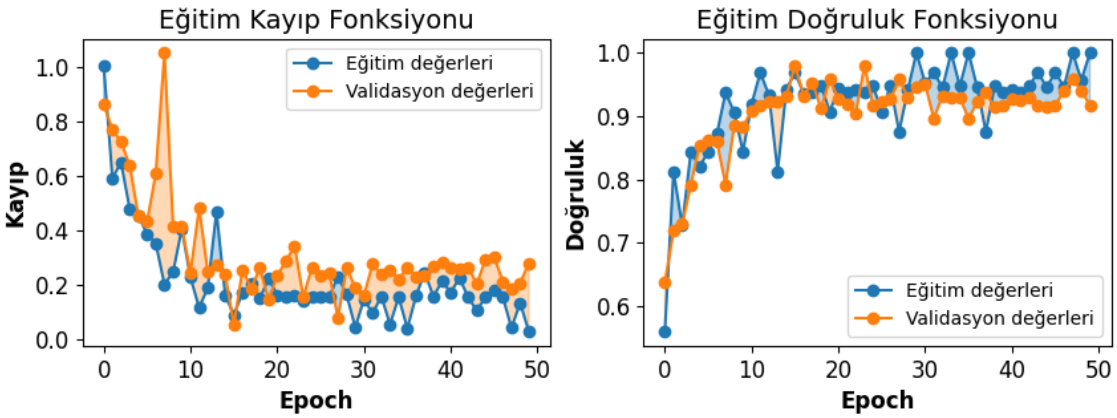


**Şekil 5.7:** Yedinci, modelimizin eğitim ve kayıp fonksiyon grafikleri

Birçok değerlendirme metriğine göre Xception ve VGG19 tabanlı üçüncü ve yedinci yöntemlerimizin en başarılı modeller olduğu anlaşılmıştır. VGG19 modeli başarılı bir sınıflandırma modelidir. Özellikle derin katmanlı mimarisi, karmaşık örüntülerden ince ayrıntılar yakalamasına büyük fayda sağlamaktadır. Xception ise daha az parametre kullanarak daha karmaşık özellikleri öğrenebilen nispeten yeni ve gelişmiş bir mimaridir. Ancak çalışmada bu modelleri daha da iyileştirmeye çalıştık. Bunu başarmak ve modellerimizi iyileştirmek için geliştirdiğimiz sınıflandırıcı, modellerin performansının artırılmasında etkili olmuştur. Mimarilere daha karmaşık katmanların eklenmesiyle tasarlanan yedinci modelimiz daha derin ve daha karmaşık bir mimariye ulaşmıştır. Eğitim setinde en yüksek doğruluk değerine ulaşan yedinci modelimiz, daha fazla toplu normalleştirme, yoğun katman ve daha fazla nörona sahiptir. Bu katmanlar modelin daha karmaşık özellikler öğrenmesine yardımcı olmuştur. Bu katmanlar, modelimizin daha iyi genelleme yapmasını sağlamıştır. Bu sayede diğer modellere kıyasla daha yüksek doğruluk puanına ulaşmasına yardımcı olmuştur. Özgün tasarımımız olan birinci modelde küçük çekirdek filtreli katmanlar kullanarak bir mimari tasarım yaptık. Ancak bu modelimizde doğruluk puanı 0.8'in altında kalmaktadır.

## 5.1. DEĞERLENDİRME METRİKLERİ

Tez çalışmasında geliştirilen birinci modelimiz olan özgün mimarimizin ortalama performansı, diğer modellere kıyasla düşük sonuç elde etmiştir. Ancak modelin başarılı yönlerine bakacak olursak, KG sınıfında özellikle %99 oranında yüksek duyarlılık ile başarılı tahminler yapmıştır. AH sınıfında ise %95 oranında yüksek bir kesinlik puanı olmasına rağmen, %50 gibi oldukça düşük bir duyarlılığı vardır. Sonuçlar, modelimizin AH sınıfındaki birçok AH pozitif deneği hatalı tahmin ettiğini göstermektedir.

Xception tabanlı bir yöntem olan ikinci modelimizin performans metrikleri değerlendirildiğinde, birinci yönteme göre performansta yüksek bir iyileşme söz konusudur. Modelimiz, AH tanımlarken %95 oranında kesinlik skoru elde etmiştir. %95 kesinlik puanı, modelin AH sınıfındaki pozitif tahminlerinin oldukça güvenilir olduğunu ve yanlış pozitif tahminlerin çok az olduğunu göstermektedir. Modelimiz AH sınıfında doğru pozitifleri yakalamada çok başarılı olmuştur.

Üçüncü modelimiz de Xception tabanlı bir yöntemdir. AH %97, HBB %91 ve KG %92 kesinlik puanı elde etmiştir. Model genel olarak başarılıdır. Ancak HBB tanımlama performansı, diğer sınıflandırma sonuçlarının biraz gerisindedir.

Dördüncü yöntemimizde VGG16 tabanlı bir mimari test ettik. Model, AH ve KG sınıfında duyarlılık puanı olarak %92 elde etmiştir. Sonuçlar, bu modelin AH ve KG sınıfındaki pozitif örnekleri yakalamada başarılı olduğunu göstermektedir. Ancak modelimizin HBB sınıfındaki duyarlılığı %63 olarak kalmıştır. Bu yöntemimiz, AH/KG tabanlı ikili bir sınıflandırma işleminde kullanılabilecek bir yöntem olarak önerilebileceğini göstermektedir. Ancak özellikle AH erken tanısı için kullanılabilecek başarılı bir yöntem olarak karşımıza çıkmamaktadır.

VGG16 tabanlı modelimizin performansını artırmak amacıyla test edilen beşinci modelimizin sonuçları, dördüncü modelimize göre daha iyidir. Beşinci modelimiz, AH ve KG sınıflarında sırasıyla %93 ve %94 duyarlılık skoru ile güçlü bir performans sergilemektedir. Ayrıca HBB sınıfında %90 kesinlik değeri yakalamıştır. Ancak HBB için duyarlılık değeri %70'in altındadır. Yani modelin HBB pozitif örnekleri yakalama konusundaki performansı zayıftır. Beşinci modelimiz de dördüncü modelimiz gibi HBB sınıfı tahmini için duyarlılık açısından iyileştirmeye ihtiyaç duymaktadır.

Altıncı modelimizi değerlendirdiğimizde, KG sınıfındaki duyarlılığı %93'tür. Model, KG sınıfındaki pozitif örnekleri yakalama konusunda başarılıdır. Ancak modelimizin HBB sınıfına ait duyarlılığı %74 olup, diğer modellere kıyasla düşük bir puandır. Modelin HBB sınıfındaki pozitif örnekleri yakalama konusundaki performansı zayıftır.

Yedinci modelimiz ise yüksek kesinlik, duyarlılık ve F1-skoru ile genel olarak diğer modellere kıyasla üçüncü modelimizle birlikte en iyi performansı sergilemektedir. Sonuçlar, yedinci modelin çeşitli sınıflarda güçlü bir tahmin gücüne sahip olduğunu gösterir. AH sınıfında %97 kesinlik, %92 duyarlılık elde etmiştir. Yani AH sınıfında hem pozitif tahminlerin doğruluğunun yüksek olduğunu hem de gerçek pozitiflerin büyük bir kısmını başarıyla yakalayabildiğini gösterir. Modelimiz ayrıca bizim için önemli bir kriter olan HBB sınıfında %89 duyarlılık puanı elde etmiştir. Modelimizin HBB sınıfındaki yüksek duyarlılığı, gerçek pozitiflerin çoğunun doğru bir şekilde tanımlandığını gösterir. Tez kapsamında tecrübe edilen 7 farklı modele ait performans metrik sonuçları Tablo 5.1'de gösterilmektedir.

**Tablo 5.1:** Modellerin performans sonuçları

| **Modeller** | **Sınıf** | **Kesinlik** | **Duyarlılık** | **F1-Skoru** | **Doğruluk** |
|---|---|---|---|---|---|
| Birinci model | AH | 95 | 50 | 65 | %71 |
| | HBB | 66 | 65 | 65 | |
| | KG | 66 | 99 | 79 | |
| | Ortalama | 76 | 71 | 70 | |
| İkinci model | AH | 95 | 88 | 91 | %91 |
| | HBB | 88 | 89 | 88 | |
| | KG | 90 | 96 | 93 | |
| | Ortalama | 91 | 91 | 91 | |
| Üçüncü model | AH | 97 | 90 | 93 | %93 |
| | HBB | 91 | 91 | 91 | |
| | KG | 92 | 99 | 95 | |
| | Ortalama | 93 | 93 | 93 | |
| Dördüncü model | AH | 82 | 92 | 87 | %82 |
| | HBB | 85 | 63 | 73 | |
| | KG | 80 | 92 | 86 | |
| | Ortalama | 83 | 82 | 82 | |
| Beşinci model | AH | 84 | 93 | 88 | %85 |
| | HBB | 90 | 69 | 78 | |
| | KG | 82 | 94 | 88 | |
| | Ortalama | 86 | 85 | 85 | |
| Altıncı model | AH | 87 | 92 | 89 | %87 |
| | HBB | 88 | 74 | 81 | |
| | KG | 85 | 93 | 89 | |
| | Ortalama | 87 | 87 | 86 | |
| Yedinci model | AH | 97 | 92 | 94 | %93 |
| | HBB | 89 | 92 | 90 | |
| | KG | 92 | 95 | 94 | |
| | Ortalama | 93 | 93 | 93 | |

Performans metrikleri genel olarak incelendiğinde, özgün mimarimiz ve VGG16 tabanlı modellerin başarısı diğer modellere göre düşük kalmıştır. Özgün mimarimiz, her ne kadar küçük çekirdek boyutlu filtrelerle tasarlanmış olsa da görüntülerdeki desenleri yakalama konusunda diğer modellere göre yetersiz kalmıştır. Ayrıca, VGG16 tabanlı modellerimiz diğer TÖ tabanlı yöntemlere göre nispeten daha basit bir mimariye sahiptir. Bu nedenle paternler arasındaki ilişkiyi yakalama konusunda diğerlerine kıyasla yetersiz kalmıştır. VGG19 ve Xception tabanlı mimarilerimiz daha karmaşık tasarımlardır. Bu modellerin başarısını yoğun bloklardan oluşan karmaşık mimarilerine bağlayabiliriz. Ayrıca, Xception mimarisi standart konvolüsyon katmanları yerine derin ayrık konvolüsyonları kullanır. Ayrık konvolüsyonlar, modelin performansını artırırken parametre sayısını ve hesaplama maliyetini azaltır. Böylece, modelin daha verimli ve hızlı çalışmasını sağlar.

## 5.2. MODELLERİN SINIFLANDIRMA SONUÇLARI

Bir karışıklık matrisi, denetimli bir öğrenme modelinin performansının görselleştirilmesini sağlayan bir yöntemdir. Çıktının iki veya daha fazla sınıfa ait olabileceği sınıflandırma sonuçlarını görselleştirmek için kullanılır. Matris, tahmin edilen ve gerçek sınıflandırmaları yan yana göstererek modelin nerede iyi performans gösterdiğini ve nerede hata yaptığını anlamayı kolaylaştırır (Hinterreiter ve diğ., 2020). Tez kapsamında AH teşhisi ve erken tanısı için önerilen yedi modelin test veri setine ait karışıklık matrisi grafikleri Şekil 5.8'de sırasıyla sunulmaktadır.

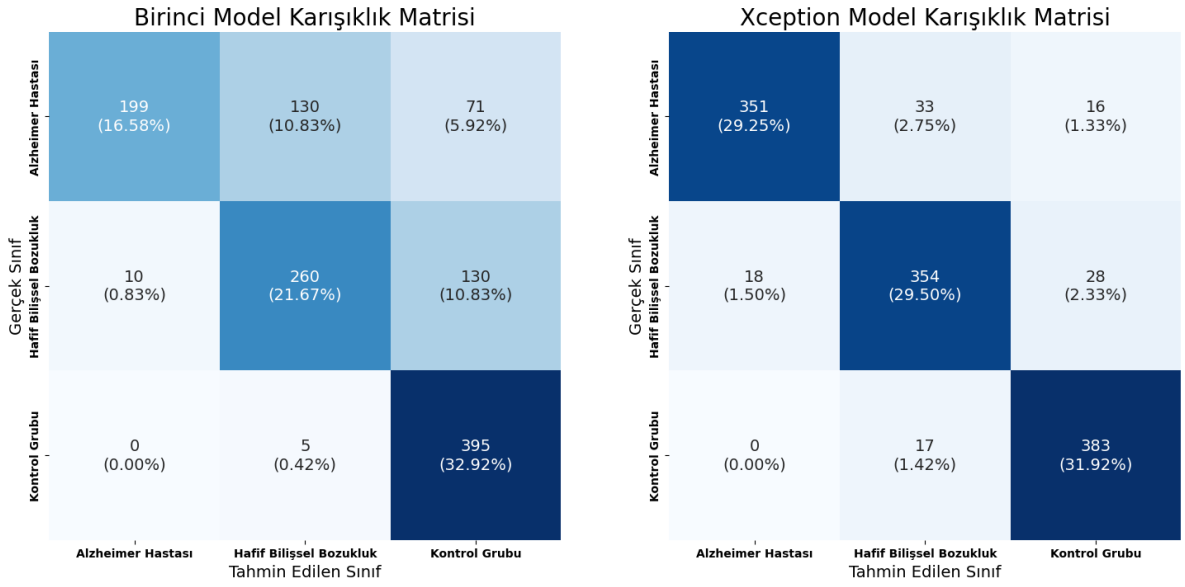

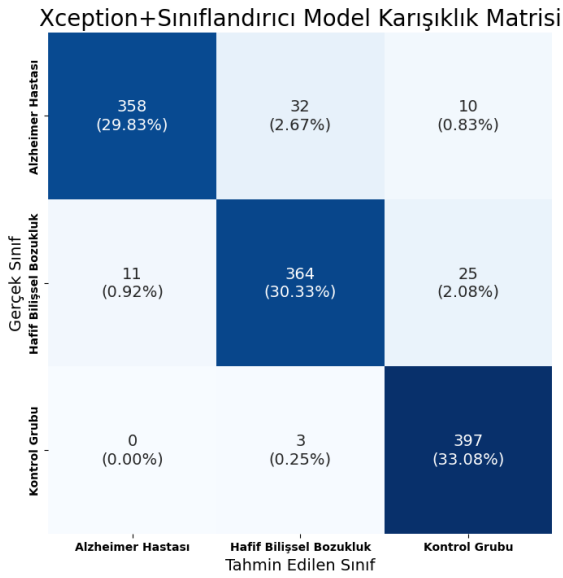
Xception+Sınıflandırıcı Model Karışıklık Matrisi
Gerçek Sınıf
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
358 (29.83%)
32 (2.67%)
10 (0.83%)
11 (0.92%)
364 (30.33%)
25 (2.08%)
0 (0.00%)
3 (0.25%)
397 (33.08%)
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
Tahmin Edilen Sınıf

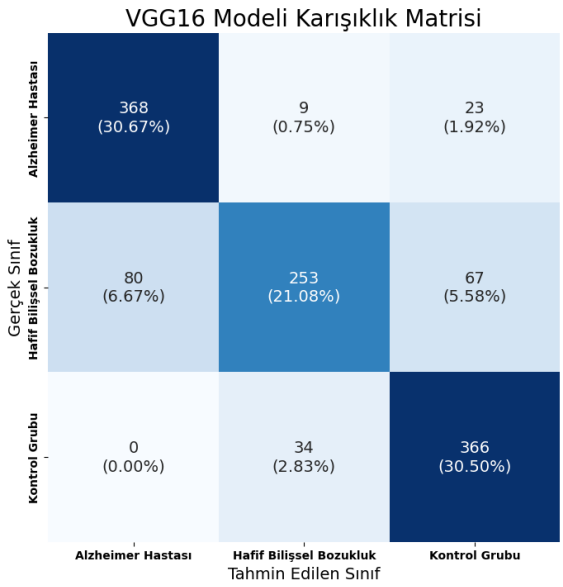
VGG16 Modeli Karışıklık Matrisi
Gerçek Sınıf
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
368 (30.67%)
9 (0.75%)
23 (1.92%)
80 (6.67%)
253 (21.08%)
67 (5.58%)
0 (0.00%)
34 (2.83%)
366 (30.50%)
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
Tahmin Edilen Sınıf

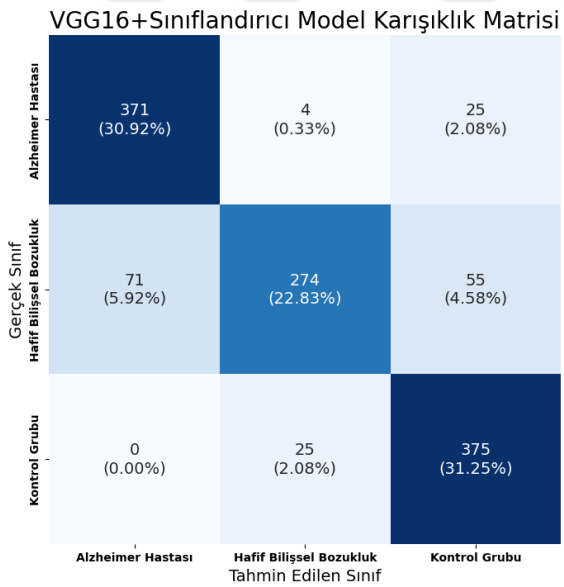
VGG16+Sınıflandırıcı Model Karışıklık Matrisi
Gerçek Sınıf
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
371 (30.92%)
4 (0.33%)
25 (2.08%)
71 (5.92%)
274 (22.83%)
55 (4.58%)
0 (0.00%)
25 (2.08%)
375 (31.25%)
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
Tahmin Edilen Sınıf

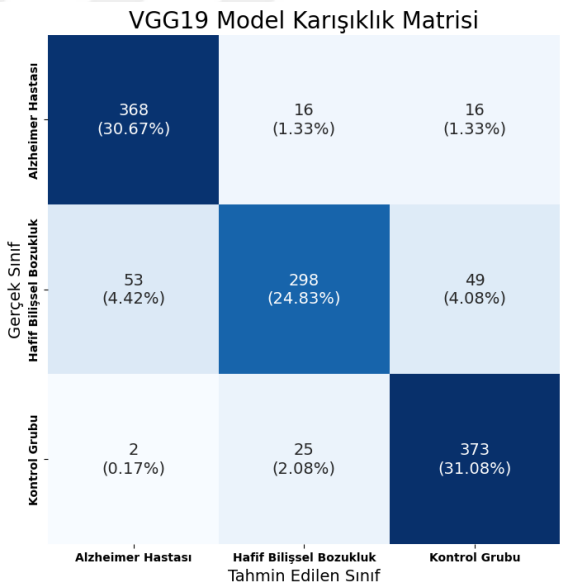
VGG19 Model Karışıklık Matrisi
Gerçek Sınıf
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
368 (30.67%)
16 (1.33%)
16 (1.33%)
53 (4.42%)
298 (24.83%)
49 (4.08%)
2 (0.17%)
25 (2.08%)
373 (31.08%)
Alzheimer Hastası
Hafif Bilişsel Bozukluk
Kontrol Grubu
Tahmin Edilen Sınıf

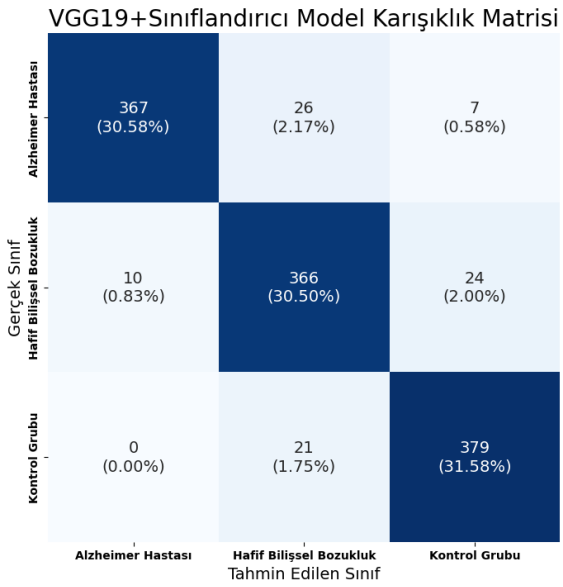


**Şekil 5.8:** Modellerin test veri seti karışıklık matrisleri

Üçüncü modelimizin karışıklık matrisi incelendiğinde, test edilen 1200 medikal görüntü karesinin 81 tanesini hatalı tahmin etmiştir. Yani 1119 görüntüyü doğru olarak etiketleyebilmiştir. Bu sayede %93 doğruluk puanını test verilerinden elde etmiştir. Dikkat edilecek bir başka husus ise KG sınıfındaki verilerin hepsinin doğru olarak sınıflandırabilmesidir. Bununla birlikte, sadece 3 adet KG grubu görüntüyü HBB olarak tanımlamıştır. 397 görüntüyü ise doğru olarak kategorilere ayırabilmiştir. Modelimizin en başarısız kısmı ise 32 adet AH görüntüsünü HBB kategorisine yerleştirmesidir. Sonuçlara baktığımızda, birçok yönden başarılı bir model geliştirmiş olduğumuz anlaşılmaktadır.

Yedinci modelimize ait karışık matris değerlendirildiğinde, test edilen 1200 medikal görüntü karesinin 88 tanesini hatalı tahmin etmiş, 1112 görüntüyü ise doğru tahmin ederek %93 gibi yüksek bir test verisi doğruluğu elde etmiştir. Yedinci modelimiz, KG/AH sınıf ayrımını hatasız yapabilmiştir. İlaveten, AH görüntülerden sadece 7 tanesini KG sınıfı olarak hatalı etiketlemiştir. En başarısız yönü ise 26 adet AH görüntüsünü HBB olarak etiketlemesidir. Bu sonuçlara göre önerilen modelimiz, AH/KG ayrımını çok yüksek başarı oranlarıyla yapabilmektedir.

Bir başka performans metriği ise Alıcı İşletim Karakteristiği (ROC)'dir. Bu metrik, ikili bir kıyaslama işlemi için modelin performansını değerlendirmek amacıyla kullanılan grafiksel bir gösterimdir. Farklı eşik ayarları arasında gerçek pozitif oranı (duyarlılık) ve yanlış pozitif

oranı (1-özgüllük) arasındaki değiş tokuşu gösterir. İdeal bir ROC eğrisinde doğru pozitif oran değerinin 1 olması hedeflenir (Carter ve diğ., 2016). Şekil 5.9'da modellerin test verilerinden elde edilen ROC grafikleri sunulmaktadır.

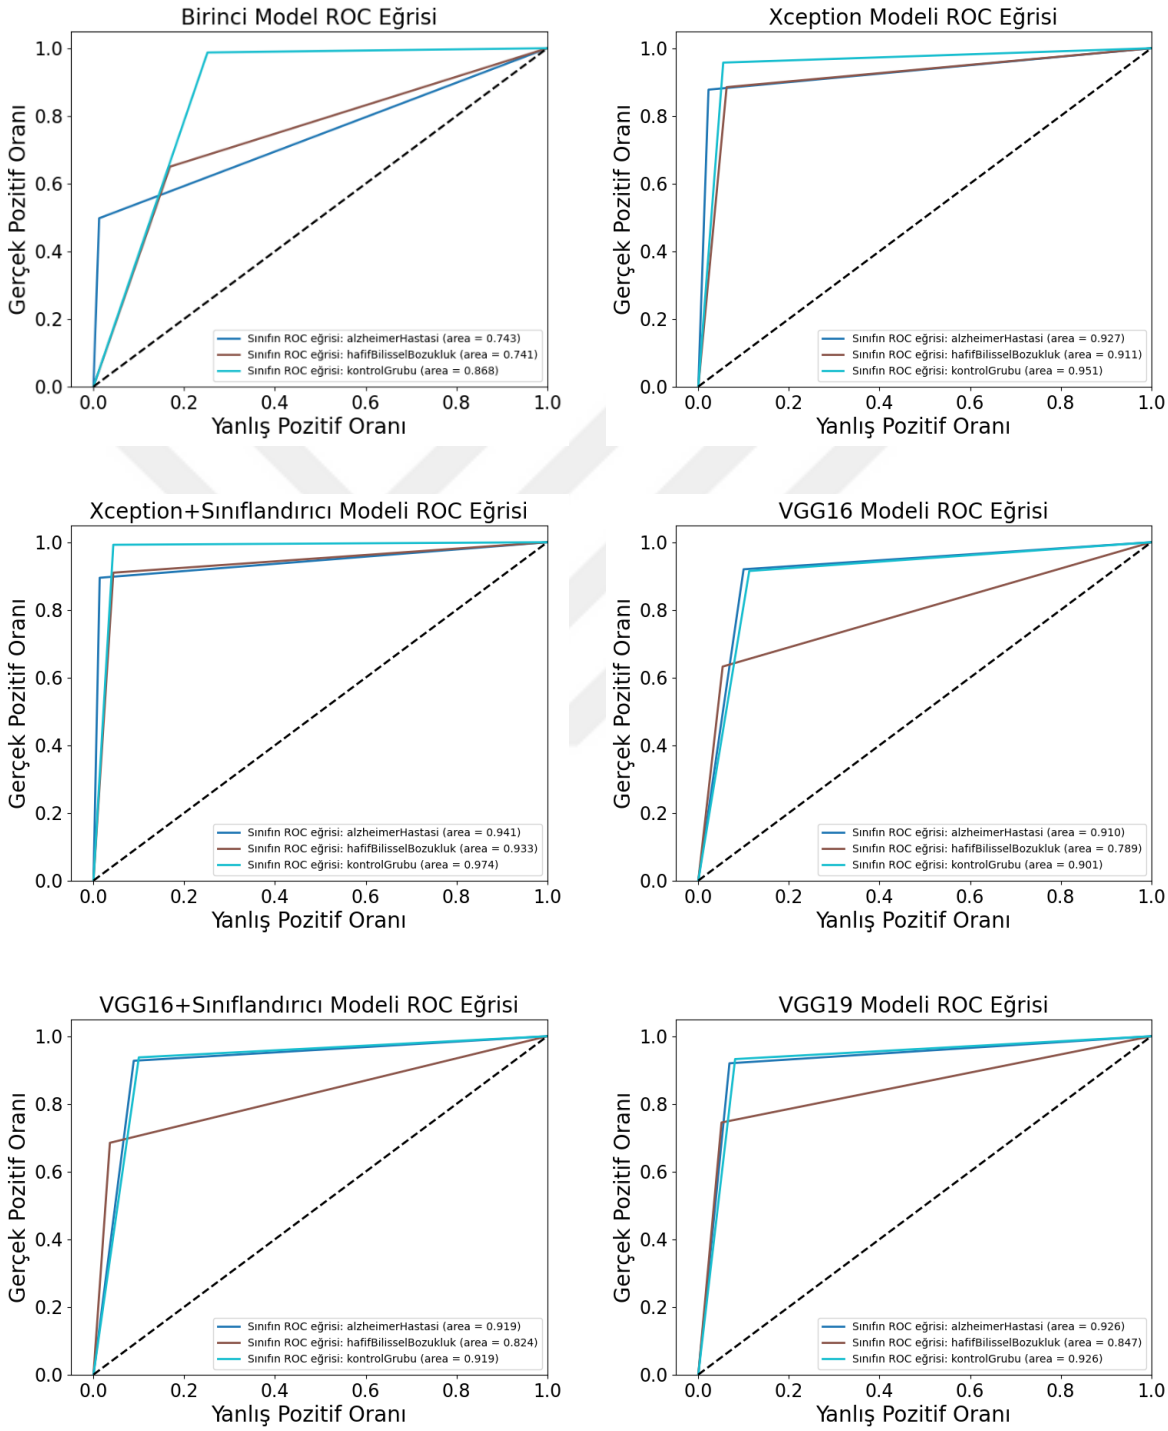

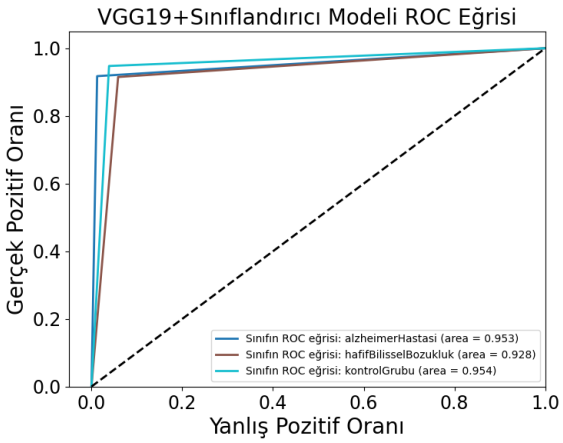


**Şekil 5.9:** Modellerin test veri seti ROC eğrileri

Üçüncü modelimiz, AH için 0,94; KG için ise 0,97 AUC puanı elde etmiştir. Ayrıca HBB sınıfı tahmininde 0,93 gibi yüksek bir skor elde etmiştir. Özellikle KG sınıfı için 0,97 puanı, modelin KG'yi doğru bir şekilde tanımlayabildiğini gösterir. Yani modelimiz sağlıklı bireyleri tanımada çok başarılıdır. Ayrıca 0,93'e yakın bir HBB puanı elde ederek AH erken tanısı için potansiyel bir aday yöntem olarak kullanılabileceğini ispatlamaktadır.

Yedinci modelimiz, AH için 0,95; KG için ise 0,95 AUC puanı elde etmiştir. Özellikle HBB sınıfı tahmininde 0,93'e yakın bir puan elde ederek, hem AD/KG ayrımında başarılı bir yöntem olduğunu hem de erken evre AH teşhisinde kullanılabilecek başarılı bir yöntem olarak kullanılma potansiyeli olduğunu kanıtlamaktadır.

## 5.3. GÜÇLÜ YÖNLER VE SINIRLAMALAR

ESA'lar görüntü tanıma görevlerinde oldukça etkili DL yöntemleridir. Ghazal ve diğ. (2022) çalışmasında derin öğrenme (DÖ) tabanlı MR görüntü analizi ile %91 doğruluk oranıyla başarılı bir AH erken tanı sistemi önermişlerdir. Tez kapsamında elde edilen sonuçlar, DÖ tabanlı görüntü analiz yöntemlerinin AH, HBB ve sağlıklı bireyler arasında yüksek doğrulukla sınıflandırma yapabildiğini göstermektedir. (Rasool ve Bhat, 2024) çalışmalarında, DÖ teknikleri ile manuel özellik mühendisliğine gerek kalmadan hem zaman alıcı hem de uzmanlık gerektiren işlemleri otomatik ve verimli bir şekilde gerçekleştirmişlerdir. Tez kapsamında kullanılan ESA tabanlı yöntemler de hastalıkla ilişkili özellikleri başarıyla yakalayabilmiştir.

TÖ modellerinin kullanılması, sıfırdan bir model eğitmeye gerek kalmadan farklı görevler ve veri kümeleri için başarılı çözümler sunmaktadır. TÖ yöntemleri, özellikle medikal görüntüler gibi sınırlı veri kümeleri üzerinde çalışıldığında performansı ve doğruluğu önemli ölçüde artırabilir. İlaveten, TÖ yöntemleri büyük ve çeşitli veri kümelerinden öğrenilen örüntüleri modelin genelleştirme yeteneğine dahil ederek yeni ve daha önce görülmemiş verilere karşı daha başarılı bir şekilde uyum sağlamasına yardımcı olabilir. Çalışmamızda test ettiğimiz TÖ tabanlı modellerimiz %88 ile %94 arasında değişen ortalama tahmin doğrulukları elde etmiştir. Payan ve Montana (2015) çalışmalarında AH ile sağlıklı bireyleri %95 doğruluk oranıyla sınıflandırarak yüksek bir başarı elde etmişlerdir. Araştırmacılar 3B görüntüler kullanarak modellerinin doğruluk performansını artırmıştır; ancak biz çalışmamızda 2B görüntüler kullandığımız için sonuçlarımız nispeten daha düşük kalmıştır. Bununla birlikte 3B görüntülerin kullanımı güçlü donanım maliyetlerini gerektirmektedir. Biz çalışmamızda 2B görüntüler yardımıyla 3B görüntülerden elde edilen doğruluk değerlerine yaklaştık. Kısaca tez çalışmamızda elde edilen sonuçlar ESA tabanlı yöntemlerin yüksek doğrulukla AH ve HBB tahmini edebildiğini göstermektedir. Tez kapsamında elde edilen sonuçlar analiz edildiğinde, ESA tabanlı yöntemlerin HBB evresinde bir hastayı yüksek doğruluk oranlarıyla erken teşhis edebilme potansiyeline sahip olduğunu göstermektedir. Bu yöntemler, özellikle hekimlere karar alma süreçlerinde bir destek sistemi olarak büyük fayda sağlayabilir. Ahmed ve diğ. (2020) çalışmalarında %93 doğruluğa varan oranlarla HBB evresini ESA tabanlı sınıflandırıcılarla tahmin etmişlerdir. Paralel bir şekilde, tez çalışmamızda ESA tabanlı yöntemlerin AH'nin geçiş evresi olan HBB evresini başarıyla tanımlayabildiği gösterilmiştir.

ESA ve TÖ tabanlı yöntemlerin avantajlarına rağmen bu yöntemlerin kullanıldığı uygulamalarda hala devam eden bazı sorunlar bulunmaktadır. Derin ağların kullanıldığı modellerden optimum performans elde edebilmek için büyük miktarlarda etiketli eğitim verisi gerekmektedir. Özellikle tıbbi görüntüleme verilerine ait büyük ve açıklamalı veri kümelerine ulaşmak, zor ve zahmetli prosedürleri gerektirebilir. Ayrıca, kısıtlı veri kümeleri üzerinde eğitilmiş DL tabanlı modellerde ezber öğrenme riski bulunmaktadır (Yamanakkanavar ve diğ., 2020; Rasool ve Bhat, 2024). Bu riski minimize etmek için çalışmamızda veri artırımı teknikleri uygulandı ve ağ tasarımı sırasında rastgele nöronların kapatıldığı dropout yöntemleri kullanıldı. Tıbbi veri kümeleri genellikle bazı sınıfların (örneğin sağlıklı bireyler) diğerlerinden (örneğin AH veya HBB) daha yaygın olduğu dengesiz veri kümeleri şeklinde olabilmektedir. Bu dengesizlik, çoğunluk sınıfında iyi performans gösteren ancak azınlık

sınıflarında kötü performans gösteren önyargılı modellerin ortaya çıkmasına yol açabilir. Ayrıca, ESA'lar karmaşık mimarileri nedeniyle genellikle "kara kutu" modeller olarak kabul edilir ve bu durum tıbbi uygulamalarda sonucun yorumlanabilmesini zorlaştırarak önemli bir dezavantaj oluşturabilir (Ajagbe ve diğ., 2021). ESA tabanlı yöntemlerin bir diğer sorunu ise model eğitimi için gereken yüksek donanım kaynaklarıdır. Özellikle TÖ tabanlı yöntemler, hesaplama açısından yüksek kaynak ihtiyacı duyabilirler (Attallah, 2023; Acharya ve diğ., 2021). Bu nedenle, DL tabanlı yöntemler klasik MÖ tabanlı yöntemlere kıyasla yatırım maliyeti daha yüksek çözümler olarak karşımıza çıkabilmektedir. Sonuç olarak, AH, HBB ve sağlıklı bireylerin tahmini işlemlerinde ESA ve TÖ tabanlı yöntemler kullanmak, yüksek doğruluk ve erken teşhis potansiyeline sahip güçlü bir tekniktir. Ancak, bu yöntemlerin veri bağımlılığı, aşırı uyum riski, yorumlanabilirlik ve hesaplama kaynakları gibi zorluklarını dikkatlice değerlendirmek gerekmektedir.

# 6. SONUÇ VE ÖNERİLER

Sinir bilimi, tıbbi görüntüleme ve yapay zeka arasında köprü kuran bu disiplinler arası yaklaşım aracılığıyla, AH'ye yönelik teşhis yeteneklerinin geliştirilmesine yönelik süregelen çabalara katkıda bulunmayı amaçlıyoruz. MRG verilerinden anlamlı içgörüler elde etmek için DÖ modellerinin gücünden yararlanarak, bu yıkıcı nörolojik bozukluktan etkilenen bireyler için erken tespit, kişiselleştirilmiş tedavi planlaması ve sonuçta iyileştirilmiş sonuçlar sağlama hedeflenmektedir.

Makine öğrenimi, derin öğrenme ve diğer yapay zeka tekniklerinin hızlı yükselişi, tıbbi görüntü işleme alanında büyük ilerlemelere katkıda bulunmaktadır. Bu ilerlemeler, sağlık sistemlerini zamanla yapay zeka tabanlı sistemlerle birleştirmeye yönlendirmektedir. Bu süreçte yapay zeka araştırmaları önemli bir çalışma alanı olarak karşımıza çıkmaktadır. Ayrıca her geçen gün üretilen yeni veri yığınları, kestirimci yapay zeka teknolojilerinin gerçek dünya problemlerinde kullanımını hızlandırmaktadır. DÖ, insan sinir ağlarından esinlenerek oluşturulan çok sayıda yapay nöron katmanından oluşan bir makine öğrenme yaklaşımıdır. Katman sayısının artması ağı derinleştirir. Böylelikle derin ağlar, insan beynine daha benzer bir hale gelmektedir. Artan derinlik, bu yöntemlerin karmaşıklığını artırarak derin öğrenmenin daha çekici ve gelişmiş işlevlere olanak sağlamasına katkıda bulunmaktadır.

Tez çalışmasında makine öğrenimi tabanlı yöntemler kullanılarak AH tanısı ve erken teşhisi için yedi farklı yöntem test edilmiştir. Bunlar arasında üçüncü ve yedinci TÖ tabanlı yöntemlerimiz en başarılı tahmin işlemini gerçekleştirmiştir. Test edilen yöntemler farklı DÖ mimarilerine dayanmaktadır. Veri kümesi olarak, halka açık ve diğer araştırmacılar tarafından da erişilebilecek bir görüntü veritabanı tercih edilmiştir. Bu sayede çalışmamızın diğer araştırmacılar tarafından tekrarlanabilirliği amaçlanmıştır. Veri kümemiz AH HBB ve KG olmak üzere çoklu bir sınıflandırma işlemi için düzenlenmiştir. Farklı modeller ve teknikler yardımıyla sınıflandırma sonuçlarımız test edilmiştir. Bu amaçla ilk yöntemimizde test etmek için özgün bir DÖ mimarisi tasarlanmıştır. Ancak birinci yöntemimizde beklenen performans değerleri elde edilememiştir. Bunun nedeni, özgün tasarım modelimizin eğitim veri setindeki

örnek sayısından kaynaklanan yetersiz öğrenme problemidir. Medikal görüntüler kısıtlı ve erişimi zor veri kümeleridir. Bu nedenle özgün mimarimiz, istediğimiz performans sonuçlarına ulaşmak için hastalığa ait karmaşık ilişkileri yakalayamamıştır. Ayrıca büyük miktarda veri kümesine sahip olmamız durumunda, bu görüntülerin işlenmesi yüksek hesaplama maliyetleri ve donanım gereksinimleri ile karşılaşılması sorununu beraberinde getirecektir. Bu nedenle diğer yöntemlerde TÖ tabanlı derin öğrenme modelleri test edilmiştir. VGG16 tabanlı yöntemlerimiz ise basit mimarilerinden dolayı beyin dokusunda meydana gelen minimal deformasyonları yakalamada diğer TÖ tabanlı yöntemlere kıyasla düşük performans sergilemiştir. Geleneksel konvolüsyonlar yerine Xception tabanlı modellerimiz, VGG16 tabanlı yöntemlere ve birinci modelimize göre daha başarılı sonuçlar elde etmiştir. Xception mimarisinin daha derin ve geniş bir yapıya sahip olmasından dolayı daha karmaşık ve ayrıntılı özellikleri öğrenebilmiştir. Bu sayede özellikle karmaşık veri setleri üzerinde daha iyi performans sağlamıştır. VGG19 tabanlı mimarilerimiz, daha yüksek katmanlı derin yapısı sayesinde derin özellikleri öğrenebilmiştir. Özellikle VGG19 yöntemimize geliştirdiğimiz özgün sınıflandırıcının eklenmesi, VGG19 tabanlı mimarimizin performansını artırmıştır. Küçük filtreli bir sınıflandırıcının, HBB gibi minimal değişikliklerin meydana geldiği ve ince ayrıntıların yakalanması gereken görevlerde modelin performansına katkı sunduğu görülmüştür. Test edilen yedi farklı modelin performans metriklerine göre, Xception ve VGG19 tabanlı yöntemlerimiz diğer yöntemlerimize göre daha başarılı modeller olduğu ortaya çıkmıştır. Doğruluk, F1-skoru, hassasiyet ve duyarlılık performans metriklerine göre özellikle Xception+sınıflandırıcı ve VGG19+sınıflandırıcı modellerimizin en başarılı yöntemler olduğu görülmüştür.

Tez kapsamında tecrübe ettiğimiz bazı yöntemlerimiz istediğimiz performans sonuçlarını göstermese de tüm test edilen yöntemlerimiz yaklaşık olarak en az %80'in üzerinde başarı ile tahmin işlemi gerçekleştirmiştir. Bu sonuçlar derin öğrenme tabanlı yöntemlerin yüksek başarı oranlarında hekimlere karar verme sürecinde bir yardımcı olarak kullanılabileceğini göstermektedir.

# KAYNAKLAR


[1] Abbas, S.Q., Chi, L. ve Chen, Y.P.P. 2023. Transformed domain convolutional neural network for Alzheimer's disease diagnosis using structural MRI. *Pattern Recognition*. https://doi.org/10.1016/j.patcog.2022.109031.

[2] Abdou, M.A. 2022. Literature review: efficient deep neural networks techniques for medical image analysis. *Neural computing & applications*. *34*(8), 5791–5812. https://doi.org/10.1007/s00521-022-06960-9.

[3] AbdulAzeem, Y., Bahgat, W.M. ve Badawy, M. 2021. A CNN based framework for classification of Alzheimer's disease. *Neural computing & applications*. *33*(16), 10415–10428. https://doi.org/10.1007/s00521-021-05799-w.

[4] Abed, M. T., Fatema, U., Nabil, S. A., Alam, M. A., ve Reza, M. T., 2020, Alzheimer's disease prediction using convolutional neural network models leveraging pre-existing architecture and transfer learning. In 2020 joint 9th international conference on informatics, electronics and vision (ICIEV) and 2020 4th international conference on imaging, vision and pattern recognition (icIVPR) (1-6). IEEE. https://10.1109/ICIEVicIVPR48672.2020.9306649.

[5] Abed, M.T., Nabil, S.A. ve Fatema, U. 2019. *Early prediction of Alzheimer's disease using convolutional neural network* (Doctoral dissertation).

[6] Acharya, H., Mehta, R. ve Kumar Singh, D. 2021. Alzheimer disease classification using transfer learning In: 2021 5th International Conference on Computing *Methodologies and Communication (ICCMC).* IEEE. https://doi.org/10.1109/ICCMC51019.2021.9418294.

[7] Aderghal, K., Afdel, K., Benois-Pineau, J. ve Catheline, G. 2020. Improving Alzheimer's stage categorization with Convolutional Neural Network using transfer learning and different magnetic resonance imaging modalities. *Heliyon*. *6*(12), p.e05652. https://doi.org/10.1016/j.heliyon.2020.e05652.

[8] Ahmadi, M., Javaheri, D., Khajavi, M., Danesh, K. ve Hur, J. 2024, A deeply supervised adaptable neural network for diagnosis and classification of Alzheimer's severity using multitask feature extraction. *Plos one, 19*(3), e0297996. https://doi.org/10.1371/journal.pone.0297996.

[9] Ahmed, S., Kim, B.C., Lee, K.H., Jung, H.Y. ve Alzheimer's Disease Neuroimaging Initiative 2020. Ensemble of ROI-based convolutional neural network classifiers for staging the Alzheimer disease spectrum from magnetic resonance imaging. *PloS one*. *15*(12), p.e0242712. https://doi.org/10.1371/journal.pone.0242712.

[10] Ajagbe, S.A., Amuda, K.A., Oladipupo, M.A., Afe, O.F. ve Okesola, K.I. 2021. Multi-classification of alzheimer disease on magnetic resonance images (MRI) using deep convolutional neural network (DCNN) approaches. *International journal of advanced computer research. 11*(53), 51–60. http://dx.doi.org/10.19101/IJACR.2021.1152001.

[11] Al-Adhaileh, M.H. 2022. Diagnosis and classification of Alzheimer's disease by using a convolution neural network algorithm. *Soft computing. 26*(16), 7751–7762. https://doi.org/10.1007/s00500-022-06762-0.

[12] Ali, A., Sarvamangala, D.R., Sundaram, A. ve Rashmi, C. 2023. *Alzheimer's Detection and Classification Using Fine-Tuned Convolutional Neural Network In: Fuzzy Logic Applications in Computer Science and Mathematics.*, 125–141. https://doi.org/10.1002/9781394175130.ch8.

[13] Allioui, H., Sadgal, M. ve Elfazziki, A. 2020. Utilization of a convolutional method for Alzheimer disease diagnosis. *Machine vision and applications. 31*(4). https://doi.org/10.1007/s00138-020-01074-5.

[14] AlSaeed, D., ve Omar, S. F. ,2022, Brain MRI analysis for Alzheimer's disease diagnosis using CNN-based feature extraction and machine learning. *Sensors, 22*(8), 2911. https://doi.org/10.3390/s22082911.

[15] Al-Shoukry, S., Rassem, T. H., ve Makbol, N. M. , 2020,. Alzheimer's diseases detection by using deep learning algorithms: a mini-review. *IEEE Access,* 8, 77131-77141. https://10.1109/ACCESS.2020.2989396.

[16] Altınkaya, E., Polat, K. ve Baraklı, B. 2020. Detection of Alzheimer's disease and dementia states based on deep learning from MRI images: a comprehensive review. *Journal of the Institute of Electronics and Computer. 1*(1), 39–53. https://doi.org/10.33969/JIEC.2019.11005.

[17] Arafa, D.A., Moustafa, H.E.-D., Ali, H.A., Ali-Eldin, A.M.T. ve Saraya, S.F. 2023. A deep learning framework for early diagnosis of Alzheimer's disease on MRI images. *Multimedia tools and applications*. https://doi.org/10.1007/s11042-023-15738-7

[18] Arslan, N.N. ve Özdemir, D. 2024. Analysis of CNN models in classifying Alzheimer's stages: comparison and explainability examination of the proposed separable convolution-based neural network and transfer learning models. *Signal, Image and Video Processing*. 1–15. https://doi.org/10.1007/s11760-024-03166-5.

[19] Arya, A. D., Verma, S. S., Chakarabarti, P., Chakrabarti, T., Elngar, A. A., Kamali, A. M. ve Nami, M., 2023, A systematic review on machine learning and deep learning techniques in the effective diagnosis of Alzheimer's disease. *Brain Informatics, 10*(1), 17. https://doi.org/10.1186/s40708-023-00195-7.

[20] Ashraf, A., Naz, S., Shirazi, S.H., Razzak, I. ve Parsad, M. 2021. Deep transfer learning for alzheimer neurological disorder detection. *Multimedia tools and applications. 80*(20), 30117–30142.

[21] Assmi, A., Elhabyb, K., Benba, A. ve Jilbab, A. 2024. Alzheimer's disease classification: a comprehensive study. *Multimedia Tools and Applications.* 1–24. https://doi.org/10.1007/s11042-024-18306-9.

[22] Attallah, O., 2023, Tomato leaf disease classification via compact convolutional neural networks with transfer learning and feature selection. *Horticulturae, 9*(2), 149. https://doi.org/10.3390/horticulturae9020149.

[23] Awarayi, N.S., Twum, F., Hayfron-Acquah, J.B. ve Owusu-Agyemang, K. 2024. A bilateral filtering-based image enhancement for Alzheimer disease classification using CNN. *PloS one. 19*(4), p.e0302358. https://doi.org/10.1371/journal.pone.0302358.

[24] Bae, J.B., Lee, S., Jung, W., Park, S., Kim, W., Oh, H., Han, J.W., Kim, G.E., Kim, J.S., Kim, J.H. ve Kim, K.W. 2020. Identification of Alzheimer's disease using a convolutional neural network model based on T1-weighted magnetic resonance imaging. *Scientific reports. 10*(1), p.22252. https://doi.org/10.1038/s41598-020-79243-9

[25] Bagaskara, A. ve Suryanegara, M. 2021. Evaluation of VGG-16 and VGG-19 deep learning architecture for classifying dementia people In: 2021 4th International Conference of Computer and Informatics Engineering (IC2IE). *IEEE.* https://doi.org/10.1109/IC2IE53219.2021.9649132.

[26] Balaji, P., Chaurasia, M. A., Bilfaqih, S. M., Muniasamy, A. ve Alsid, L. E. G., 2023, Hybridized deep learning approach for detecting Alzheimer's disease. *Biomedicines, 11*(1), 149. https://doi.org/10.3390/biomedicines11010149.

[27] Bi, X.-A., Chen, K., Jiang, S., Luo, S., Zhou, W., Xing, Z., Xu, L., Liu, Z. ve Liu, T. 2023. Community graph convolution neural network for Alzheimer's disease classification and pathogenetic factors identification. *IEEE transactions on neural networks and learning systems.* https://10.1109/TNNLS.2023.3269446.

[28] Carcagnì, P., Leo, M., Del Coco, M., Distante, C. ve De Salve, A. 2023. Convolution neural networks and self-attention learners for Alzheimer dementia diagnosis from brain MRI. *Sensors (Basel, Switzerland). 23*(3). https://doi.org/10.3390/s23031694.

[29] Carter, J. V., Pan, J., Rai, S. N. ve Galandiuk, S., 2016, ROC-ing along: Evaluation and interpretation of receiver operating characteristic curves. *Surgery, 159*(6), 1638-1645. https://doi.org/10.1016/j.surg.2015.12.029.

[30] Chaihtra, D.H. ve Vijaya Shetty, S. 2021. Alzheimer's disease detection from brain MRI data using deep learning techniques In: 2021 2nd Global Conference for Advancement in Technology (GCAT). *IEEE.* https://10.1109/GCAT52182.2021.9587756.

[31] Chitradevi, D. ve Prabha, S. 2020. Analysis of brain sub regions using optimization techniques and deep learning method in Alzheimer disease. *Applied soft computing. 86*(105857), p.105857. https://doi.org/10.1016/j.asoc.2019.105857.

[32] Choi, B.-K., Madusanka, N., Choi, H.-K., So, J.-H., Kim, C.-H., Park, H.-G., Bhattacharjee, S. ve Prakash, D. 2020. Convolutional neural network-based MR image analysis for Alzheimer's disease classification. *Current medical imaging reviews. 16*(1), 27–35. https://doi.org/10.2174/1573405615666191021123854.

[33] Chollet, F. 2017. Xception: *Deep learning with depthwise separable convolutions In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).* IEEE.

[34] Chui, K. T., Gupta, B. B., Alhalabi, W. ve Alzahrani, F. S, 2022, An MRI scans-based Alzheimer's disease detection via convolutional neural network and transfer learning. *Diagnostics, 12*(7), 1531. https://doi.org/10.3390/diagnostics12071531.

[35] Ciurea, V. A., Covache-Busuioc, R. A., Mohan, A. G., Costin, H. P., ve Voicu, V., 2023, Alzheimer's disease: 120 years of research and progress. *Journal of medicine and life, 16*(2), 173. https://doi.org/10.25122/jml-2022-0111.

[36] Dakdareh, S.G. ve Abbasian, K. 2024. Diagnosis of Alzheimer's disease and mild cognitive impairment using convolutional neural networks. *Journal of Alzheimer's disease reports. 8*(1), 317–328. https://doi.org/10.3233/ADR-230118.

[37] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. ve Fei-Fei, L., 2009, Imagenet: A large-scale hierarchical image database. *In 2009 IEEE conference on computer vision and pattern recognition* (248-255). Ieee. https://doi.org/10.1109/CVPR.2009.5206848.

[38] Derby, C.A. 2020. Trends in the public health significance, definitions of disease, and implications for prevention of Alzheimer's disease. *Current epidemiology reports. 7*(2), 68–76. https://doi.org/10.1007/s40471-020-00231-8.

[39] Dua, M., Makhija, D., Manasa, P.Y.L. ve Mishra, P. 2020. A CNN–RNN–LSTM based amalgamation for Alzheimer's disease detection. *Journal of medical and biological engineering*. https://doi.org/10.1007/s40846-020-00556-1.

[40] Dukart, J., Mueller, K., Barthel, H., Villringer, A., Sabri, O., Schroeter, M.L. ve Alzheimer's Disease Neuroimaging Initiative 2013. Meta-analysis based SVM classification enables accurate detection of Alzheimer's disease across different clinical centers using FDG-PET and MRI. *Psychiatry research. 212*(3), 230–236. https://doi.org/10.1016/j.pscychresns.2012.04.007 .

[41] Ebrahim, D., Ali-Eldin, A.M.T., Moustafa, H.E. ve Arafat, H. 2020. *Alzheimer disease early detection using convolutional neural networks In: 2020 15th International Conference on Computer Engineering and Systems (ICCES).* IEEE. https://doi.org/10.1109/ICCES51560.2020.9334594.

[42] Ebrahimi, A., Luo, S. ve Chiong, R. 2020. *Introducing transfer learning to 3D ResNet-18 for Alzheimer's disease detection on MRI images In: 2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ).* IEEE. https://doi.org/10.1109/IVCNZ51579.2020.9290616.

[43] Ebrahimighahnavieh, M.A., Luo, S. ve Chiong, R. 2020. Deep learning to detect Alzheimer's disease from neuroimaging: A systematic literature review. *Computer methods and programs in biomedicine. 187*(105242), p.105242. https://doi.org/10.1016/j.cmpb.2019.105242.

[44] El-Assy, A. M., Amer, H. M., Ibrahim, H. M. ve Mohamed, M. A., 2024, A novel CNN architecture for accurate early detection and classification of Alzheimer's disease using MRI data. *Scientific Reports, 14*(1), 3463. https://doi.org/10.1038/s41598-024-53733-6.

[45] Erdogmus, P. ve Kabakus, A.T. 2023. The promise of convolutional neural networks for the early diagnosis of the Alzheimer's disease. *Engineering applications of artificial intelligence. 123*(106254), p.106254. https://doi.org/10.1016/j.engappai.2023.106254

[46] Fathi, S., Ahmadi, M. ve Dehnad, A. 2022. Early diagnosis of Alzheimer's disease based on deep learning: A systematic review. *Computers in biology and medicine. 146*(105634), p.105634. https://doi.org/10.1016/j.compbiomed.2022.105634.

[47] Francis, A. ve Pandian, I.A. 2021. *Early detection of Alzheimer's disease using ensemble of pre-trained models In: 2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS).* IEEE. https://doi.org/10.1109/ICAIS50930.2021.9395988.

[48] Fuadah, Y.N., Wijayanto, I., Pratiwi, N.K.C., Taliningsih, F.F., Rizal, S. ve Pramudito, M.A. 2021. *Automated classification of Alzheimer's disease based on MRI image processing using convolutional neural network (CNN) with AlexNet architecture In: Journal of physics: conference series. IOP Publishing*. https://doi.org/10.1088/1742-6596/1844/1/012020.

[49] Fulton, L.V., Dolezel, D., Harrop, J., Yan, Y. ve Fulton, C.P. 2019. Classification of Alzheimer's disease with and without imagery using gradient boosted machines and ResNet-50. *Brain sciences. 9*(9), p.212. https://doi.org/10.3390/brainsci9090212.

[50] Ganesh, D., Kumar, M.S., Aparna, M.C., Royal, M.C.J., Vinay, M.D. ve Sari, S.H. 2023. Implementation Of Convolutional Neural Networks For Detection Of Alzheimer's Disease. BioGecko, *A Journal for New Zealand Herpetology.* (01).

[51] Gao, S. ve Lima, D. 2022. A review of the application of deep learning in the detection of Alzheimer's disease. *International Journal of Cognitive Computing in Engineering.* 3, 1–8.. https://doi.org/10.1016/j.ijcce.2021.12.002.

[52] Gautam, R. ve Sharma, M. 2020. Prevalence and diagnosis of neurological disorders using different deep learning techniques: A meta-analysis. *Journal of medical systems. 44*(2), p.49. https://doi.org/10.1007/s10916-019-1519-7.

[53] Ghaffari, H., Tavakoli, H. ve Pirzad Jahromi, G. 2022. Deep transfer learning-based fully automated detection and classification of Alzheimer's disease on brain MRI. *The British journal of radiology. 95*(1136), p.20211253.. https://doi.org/10.1259/bjr.20211253.

[54] Ghazal, T.M. ve Issa, G. 2022. Alzheimer disease detection empowered with transfer learning. *Computers, Materials & Continua. 70*(3), 5005–5019.

[55] Goyal, P., Rani, R. ve Singh, K. 2024. A multilayered framework for diagnosis and classification of Alzheimer's disease using transfer learned Alexnet and LSTM. *Neural computing & applications*. *36*(7), 3777–3801. https://doi.org/10.1007/s00521-023-09301-6.

[56] Gray, K.R., Aljabar, P., Heckemann, R.A., Hammers, A., Rueckert, D. ve Alzheimer's Disease Neuroimaging Initiative 2013. Random forest-based similarity measures for multi-modal classification of Alzheimer's disease. *NeuroImage*. 65, 167–175. https://doi.org/10.1016/j.neuroimage.2012.09.065.

[57] Guerrero, R., Wolz, R., Rao, A.W., Rueckert, D. ve Alzheimer's Disease Neuroimaging Initiative (ADNI) 2014. Manifold population modeling as a neuro-imaging biomarker: application to ADNI and ADNI-GO. *NeuroImage*. 94, 275–286.. https://doi.org/10.1016/j.neuroimage.2014.03.036.

[58] Guo, Z., Chen, Q., Wu, G., Xu, Y., Shibasaki, R., ve Shao, X., 2017, Village building identification based on ensemble convolutional neural networks. *Sensors*, *17*(11), 2487. https://doi.org/10.3390/s17112487.

[59] Gupta, A., Ayhan, M. and Maida, A. 2013. Natural image bases to represent neuroimaging data In: International conference on machine learning. *PMLR*, 987–994.. https://doi.org/10.3390/s17112487.

[60] Hanbay, E. 2023. *Manyetik rezonans görüntülerinde alzheimer hastalığının tespiti için yeni derin öğrenme modellerinin geliştirilmesi*. İnönü Üniversitesi, Yüksek Lisans Tezi. Malatya.

[61] Hazarika, R. A., Kandar, D., ve Maji, A. K. (2022). A deep convolutional neural networks based approach for alzheimer's disease and mild cognitive impairment classification using brain images. *IEEE Access*, 10, 99066-99076. https://doi.org/10.1109/ACCESS.2022.3206389.

[62] He, K., Zhang, X., Ren, S. ve Sun, J. 2016. *Deep residual learning for image recognition In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE.

[63] Hinterreiter, A., Ruch, P., Stitz, H., Ennemoser, M., Bernard, J., Strobelt, H. ve Streit, M. 2022. ConfusionFlow: A model-agnostic visualization for temporal analysis of classifier confusion. *IEEE transactions on visualization and computer graphics*. *28*(2), pp.1222–1236. https://doi.org/10.1109/TVCG.2020.3012063.

[64] Huang, G., Liu, Z., Van Der Maaten, L., ve Weinberger, K. Q. 2017, Densely connected convolutional networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition*. 4700-4708.

[65] Huang, Y., Xu, J., Zhou, Y., Tong, T., Zhuang, X. ve Alzheimer's Disease Neuroimaging Initiative (ADNI) 2019. Diagnosis of Alzheimer's disease via multi-modality 3D convolutional neural network. *Frontiers in neuroscience*. 13, 509. https://doi.org/10.3389/fnins.2019.00509.

[66] Hussain, E., Hasan, M., Hassan, S.Z., Hassan Azmi, T., Rahman, M.A. ve Zavid Parvez, M. 2020. *Deep learning based binary classification for Alzheimer's disease detection using brain MRI images In: 2020 15th IEEE Conference on Industrial Electronics and Applications (ICIEA).* IEEE.. https://doi.org/10.1109/ICIEA48937.2020.9248213.

[67] Javid, S.A. and Feghhi, M.M. 2024. *Early diagnosis of Alzheimer's disease from MRI images with deep learning model In: 2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP).* IEEE, 1–5. https://doi.org/10.1109/AISP61396.2024.10475240.

[68] Jiang, X., Chang, L. ve Zhang, Y.-D. 2020. Classification of Alzheimer's disease via eight-layer convolutional neural network with batch normalization and dropout techniques. *Journal of medical imaging and health informatics. 10*(5), 1040–1048. https://doi.org/10.1166/jmihi.2020.3001.

[69] Jo, T., Nho, K. ve Saykin, A.J. 2019. Deep learning in Alzheimer's disease: Diagnostic classification and prognostic prediction using neuroimaging data. *Frontiers in aging neuroscience.* 11, 220. https://doi.org/10.3389/fnagi.2019.00220.

[70] Juanes, J.A., Ruisoto, P., Prats-Galino, A. ve Framiñán, A. 2015. *Open Source Applications for Image Visualization and Processing in Neuroimaging Training In: Human-Computer Interaction. IGI Global,* 1319–1332. https://doi.org/10.3389/fnagi.2019.00220.

[71] Kanagamani, T., Chakravarthy, V.S., Ravindran, B. ve Menon, R.N. 2023. A deep network-based model of hippocampal memory functions under normal and Alzheimer's disease conditions. *Frontiers in neural circuits.* 17, p.1092933. https://doi.org/10.3389/fncir.2023.1092933.

[72] Kang, W., Lin, L., Zhang, B., Shen, X., Wu, S. ve Alzheimer's Disease Neuroimaging Initiative 2021. Multi-model and multi-slice ensemble learning architecture based on 2D convolutional neural networks for Alzheimer's disease diagnosis. *Computers in biology and medicine. 136*(104678), p.104678. https://doi.org/10.1016/j.compbiomed.2021.104678.

[73] Karabay, G.S. ve Çavaş, M. 2022. Derin öğrenme yöntemiyle alzheimer hastalığının tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi.* 34, 879–887.. https://doi.org/10.35234/fumbd.1137246.

[74] Karakuş, E. 2020. *Alzheimerlı hastalarda klinik ve biyokimyasal parametrelerle periodontal durumlarının değerlendirilmesi*. Aydın Adnan Menderes Üniversitesi.

[75] Katti, G., Ara, S.A. ve Shireen, A. 2011. Magnetic resonance imaging (MRI)-A review. *International journal of dental clinics. 3*(1). 65–70.

[76] Kaur, S., Gupta, S., Singh, S. ve Gupta, I. 2022. Detection of Alzheimer's disease using deep convolutional neural network. *International journal of image and graphics. 22*(03), p.2140012. https://doi.org/10.1142/S021946782140012X.

[77] Kaya, M. ve Çetinkaya, Y. 2024. *A Novel Deep Learning Architecture Optimization for Multiclass Classification of Alzheimer's Disease Level.* IEEE Access. https://doi.org/10.1109/ACCESS.2024.3382947.

[78] Kerwin, D., Abdelnour, C., Caramelli, P., Ogunniyi, A., Shi, J., Zetterberg, H. ve Traber, M. 2022. Alzheimer's disease diagnosis and management: Perspectives from around the world. *Alzheimer's & dementia (Amsterdam, Netherlands). 14*(1), p.e12334. https://doi.org/10.1002/dad2.12334.

[79] Kezzal, C. ve Limane, M.A. 2022. *CNN Based Medical Image Classification* (Doctoral dissertation). Unıversıty Of Ouargla.

[80] Khattar, A. ve Quadri, S.M.K. 2022. Generalization of convolutional network to domain adaptation network for classification of disaster images on twitter. *Multimedia Tools and Applications.* 81, 30437–30464. https://doi.org/10.1007/s11042-022-12869-1.

[81] Khojaste-Sarakhsi, M., Haghighi, S.S., Ghomi, S.M.T.F. ve Marchiori, E. 2022. Deep learning for Alzheimer's disease diagnosis: A survey. *Artificial intelligence in medicine. 130*(102332), p.102332. https://doi.org/10.1016/j.artmed.2022.102332.

[82] Kim, J., Jeong, M., Stiles, W.R. ve Choi, H.S. 2022. Neuroimaging modalities in Alzheimer's disease: Diagnosis and clinical features. *International journal of molecular sciences. 23*(11), p.6079. https://doi.org/10.3390/ijms23116079.

[83] Kreel, L. 2008. The story behind the development of computed tomography. *Adler Museum bulletin. 34*(2), 20–24.

[84] Krizhevsky, A., Sutskever, I., and Hinton, G., 2023, ImageNet classification with deep convolutional neural networks (AlexNet) ImageNet classification with deep convolutional neural networks (AlexNet). *Actorsfit. Com.* https://doi.org/10.1145/3065386.

[85] Kumar, L. S., Hariharasitaraman, S., Narayanasamy, K., Thinakaran, K., Mahalakshmi, J. ve Pandimurugan, V., 2022, AlexNet approach for early stage Alzheimer's disease detection from MRI brain images. *Materials Today: Proceedings*, 51, 58-65. https://doi.org/10.1016/j.matpr.2021.04.415

[86] Kundaram, S.S. and Pathak, K.C. 2021. Deep learning-based Alzheimer disease detection In: Proceedings of the Fourth International Conference on Microelectronics, Computing and Communication Systems: *MCCS 2019.* Singapore: Springer, 587–597. https://doi.org/10.1007/978-981-15-5546-6_50.

[87] Lahmiri, S. 2023. Integrating convolutional neural networks, kNN, and Bayesian optimization for efficient diagnosis of Alzheimer's disease in magnetic resonance images. *Biomedical signal processing and control. 80*(104375), p.104375.. https://doi.org/10.1016/j.bspc.2022.104375.

[88] Lakhan, A., Grønli, T.-M., Muhammad, G. ve Tiwari, P. 2023. EDCNNS: Federated learning enabled evolutionary deep convolutional neural network for Alzheimer disease detection. *Applied soft computing. 147*(110804), p.110804.. https://doi.org/10.1016/j.asoc.2023.110804.

[89] Lee, D.K., In, J. ve Lee, S. 2015. Standard deviation and standard error of the mean. *Korean journal of anesthesiology. 68*(3), pp.220–223.. https://doi.org/10.4097/kjae.2015.68.3.220.

[90] LeVine III, H., 2010, *Medical imaging.* Bloomsbury Publishing USA.

[91] Li, Z. 2024. This study addresses the challenge of intelligent diagnosis in Alzheimer's Disease by employing machine learning to classify MRI images depicting various disease stages. The author conducted a comparative analysis to assess the efficacy of diverse models. *Highlights in Science, Engineering and Technology.* 85, 1101–1107. https://doi.org/10.54097/k50nbs51

[92] Lian, C., Liu, M., Zhang, J., ve Shen, D., 2018, Hierarchical fully convolutional network for joint atrophy localization and Alzheimer's disease diagnosis using structural MRI. *IEEE transactions on pattern analysis and machine intelligence*, *42*(4), 880-893. https://doi.org/10.1109/TPAMI.2018.2889096.

[93] Lim, B. Y., Lai, K. W., Haiskin, K., Kulathilake, K. S. H., Ong, Z. C., Hum, Y. C., ve Zuo, X., 2022, Deep learning model for prediction of progressive mild cognitive impairment to Alzheimer's disease using structural MRI. *Frontiers in Aging Neuroscience*, 14, 876202. https://doi.org/10.3389/fnagi.2022.876202.

[94] Lin, W., Tong, T., Gao, Q., Guo, D., Du, X., Yang, Y., Guo, G., Xiao, M., Du, M., Qu, X. ve Alzheimer's Disease Neuroimaging Initiative 2018. Convolutional neural networks-based MRI image analysis for the Alzheimer's disease prediction from mild cognitive impairment. *Frontiers in neuroscience.* 12, p.777.. https://doi.org/10.3389/fnins.2018.00777.

[95] Liu, M., Cheng, D., Yan, W. ve Alzheimer's Disease Neuroimaging Initiative 2018. Classification of Alzheimer's disease by combination of convolutional and recurrent neural networks using FDG-PET images. *Frontiers in neuroinformatics.* 12.

[96] Liu, S., Liu, S., Cai, W., Pujol, S., Kikinis, R., and Feng, D. (2014, April). *Early diagnosis of Alzheimer's disease with deep learning. In 2014 IEEE 11th international symposium on biomedical imaging (ISBI)* (1015-1018). IEEE.. https://doi.org/10.1109/ISBI.2014.6868045.

[97] Liu, Z., Lu, H., Pan, X., Xu, M., Lan, R. ve Luo, X. 2022. Diagnosis of Alzheimer's disease via an attention-based multi-scale convolutional neural network. *Knowledge-based systems.* 238(107942), p.107942. https://doi.org/10.1016/j.knosys.2021.107942.

[98] Logan, R., Williams, B.G., Ferreira da Silva, M., Indani, A., Schcolnicov, N., Ganguly, A. ve Miller, S.J. 2021. Deep convolutional neural networks with ensemble learning and generative adversarial networks for Alzheimer's disease image data classification. *Frontiers in aging neuroscience.* 13, p.720226.. https://doi.org/10.3389/fnagi.2021.720226.

[99] Mahajan, S., Bangar, G. ve Kulkarni, N. 2020. Machine Learning Algorithms for Classification of Various Stages of Alzheimer's Disease: A review. *Machine Learning.* 7, 817–824.

[100] Marcus, D.S., Wang, T.H., Parker, J., Csernansky, J.G., Morris, J.C. ve Buckner, R.L. 2007. Open Access Series of Imaging Studies (OASIS): cross-sectional MRI data in young, middle aged, nondemented, and demented older adults. *Journal of cognitive neuroscience. 19*(9), 1498–1507. https://doi.org/10.1162/jocn.2007.19.9.1498.

[101] Marzban, E.N., Eldeib, A.M., Yassine, I.A., Kadah, Y.M. ve Alzheimer's Disease Neurodegenerative Initiative 2020. Alzheimer's disease diagnosis from diffusion tensor images using convolutional neural networks. *PloS one. 15*(3), p.e0230409.

[102] Mehmood, A., Maqsood, M., Bashir, M. ve Shuyuan, Y. 2020. A deep Siamese convolution neural network for multi-class classification of Alzheimer disease. *Brain sciences. 10*(2), p.84. https://doi.org/10.3390/brainsci10020084.

[103] Nana Hermana, A., Rosmala, D. ve Gustiana Husada, M., 2021, Transfer Learning for Classification of Fruit Ripeness Using VGG16. *In Proceedings of the 2021 4th International Conference on Computers in Management and Business*. pp. 139-146. https://doi.org/10.1145/3450588.3450943.

[104] Nawaz, H., Maqsood, M., Afzal, S., Aadil, F., Mehmood, I. ve Rho, S. 2021. A deep feature-based real-time system for Alzheimer disease stage detection. *Multimedia tools and applications. 80*(28–29), 35789–35807. https://doi.org/10.1007/s11042-020-09087-y.

[105] Nawaz, H., Maqsood, M., Afzal, S., Aadil, F., Mehmood, I. ve Rho, S. 2021. A deep feature-based real-time system for Alzheimer disease stage detection. *Multimedia tools and applications. 80*(28–29), 35789–35807. https://doi.org/10.1007/s11042-020-09087-y.

[106] Negied, N. ve SeragEldin, A. 2022. Automatic detection of Alzheimer disease from 3D MRI images using deep CNNs. *International journal of advanced computer science and applications : IJACSA. 13*(12). https://doi.org/10.14569/IJACSA.2022.0131258.

[107] Nnah, C.O. ve Zhang, Y.D. 2024. Identification of Alzheimer's disease using Convolutional Neural Network. *Journal of Integrated and Advanced Engineering. 4*(1), 77–86. https://doi.org/10.51662/jiae.v4i1.144.

[108] P. Gavrikov, "visualkeras", 2020, online Available: https://github.com/paulgavrikov/visualkeras.

[109] Pathak, N., Vimal, S.K., Tandon, I., Agrawal, L., Hongyi, C. ve Bhattacharyya, S. 2022. Neurodegenerative disorders of Alzheimer, parkinsonism, amyotrophic lateral sclerosis and multiple sclerosis: An early diagnostic approach for precision treatment. *Metabolic brain disease. 37*(1), 67–104. https://doi.org/10.1007/s11011-021-00800-w.

[110] Patil, V., Madgi, M. ve Kiran, A. 2022. Early prediction of Alzheimer's disease using convolutional neural network: a review. *The Egyptian journal of neurology, psychiatry and neurosurgery. 58*(1). https://doi.org/10.1186/s41983-022-00571-w.

[111] Payan, A. ve Montana, G. 2015. *Predicting Alzheimer's disease: a neuroimaging study with 3D convolutional neural networks.* arXiv [cs.CV]. [Online]. Available from: http://arxiv.org/abs/1502.02506.

[112] Pei, Z., Wan, Z., Zhang, Y., Wang, M., Leng, C. ve Yang, Y. H., 2022, Multi-scale attention-based pseudo-3D convolution neural network for Alzheimer's disease diagnosis using structural MRI. *Pattern Recognition*, 131, 108825.. https://doi.org/10.1016/j.patcog.2022.108825.

[113] Pradhan, N., Sagar, S. ve Singh, A.S. 2024. Analysis of MRI image data for Alzheimer disease detection using deep learning techniques. *Multimedia Tools and Applications*. 83, 17729–17752. https://doi.org/10.1007/s11042-023-16256-2.

[114] Prakash, D., Madusanka, N., Bhattacharjee, S., Park, H.-G., Kim, C.-H. ve Choi, H.-K. 2019. A comparative study of Alzheimer's disease classification using multiple transfer learning models. *Journal of Multimedia Information System. 6*(4), 209–216.. https://doi.org/10.33851/JMIS.2019.6.4.209.

[115] Rajab, M. A., Abdullatif, F. A. ve Sutikno, T., 2024, Classification of grapevine leaves images using VGG-16 and VGG-19 deep learning nets. *Telkomnika (Telecommunication Computing Electronics and Control), 22*(2), 445-453.. http://doi.org/10.12928/telkomnika.v22i2.25840.

[116] Rashid, M., Singh, H. ve Goyal, V. 2020. The use of machine learning and deep learning algorithms in functional magnetic resonance imaging—A systematic review. *Expert systems. 37*(6). https://doi.org/10.1111/exsy.12644.

[117] Rasool, N. ve Bhat, J.I. 2024. Brain tumour detection using machine and deep learning: a systematic review. *Multimedia tools and applications*. https://doi.org/10.1007/s11042-024-19333-2.

[118] Raza, N., Naseer, A., Tamoor, M. ve Zafar, K., 2023, Alzheimer disease classification through transfer learning approach. *Diagnostics*, *13*(4), 801. https://doi.org/10.3390/diagnostics13040801.

[119] Roy, P., Oddin Chisty, M.M. ve Abdul Fattah, H.M. 2021. *Alzheimer's Disease Diagnosis from MRI images using ResNet-152 Neural Network Architecture In: 2021 5th International Conference on Electrical Information and Communication Technology (EICT).* IEEE.. https://doi.org/10.1109/EICT54103.2021.9733507.

[120] Roy, S.S., Sikaria, R. ve Susan, A. 2020. A deep learning based CNN approach on MRI for Alzheimer's disease detection. *Intelligent decision technologies. 13*(4), 495–505. https://doi.org/ 10.3233/IDT-190005.

[121] Saleem, T.J., Zahra, S.R., Wu, F., Alwakeel, A., Alwakeel, M., Jeribi, F. ve Hijji, M. 2022. Deep learning-based diagnosis of Alzheimer's disease. *Journal of personalized medicine. 12*(5), p.815. https://doi.org/10.3390/jpm12050815.

[122] Salehi, A.W., Baglat, P., Sharma, B.B., Gupta, G. ve Upadhya, A. 2020. *A CNN Model: Earlier Diagnosis and Classification of Alzheimer Disease using MRI In: 2020 International Conference on Smart Electronics and Communication (ICOSEC).* IEEE. https://doi.org/10.1109/ICOSEC49089.2020.9215402.

[123] Sehar, U., Kopel, J. ve Reddy, P.H. 2023. Alzheimer's disease and its related dementias in US Native Americans: A major public health concern. *Ageing research reviews. 90*(102027), p.102027. https://doi.org/10.1016/j.arr.2023.102027.

[124] Sethi, M., Ahuja, S. ve Bawa, P. 2021. *Classification of Alzheimer's disease using Neuroimaging Data by Convolution Neural Network In: 2021 6th International Conference on Signal Processing, Computing and Control (ISPCC).* IEEE. https://doi.org/10.1109/ISPCC53510.2021.960943.

[125] Sharma, G., Vijayvargiya, A. ve Kumar, R. 2021. *Comparative assessment among different convolutional neural network architectures for Alzheimer's disease detection In: 2021 IEEE 8th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON).* IEEE. https://doi.org/10.1109/UPCON52273.2021.9667607.

[126] Sharma, R., Goel, T., Tanveer, M., Lin, C.T. ve Murugan, R. 2023. *Deep learning based diagnosis and prognosis of Alzheimer's disease: A comprehensive review.* IEEE Transactions on Cognitive and Developmental Systems. https://doi.org/10.1109/TCDS.2023.3254209.

[127] Sharma, Sarang, Gupta, S., Gupta, D., Juneja, S., Mahmoud, A., El-Sappagh, S. ve Kwak, K.-S. 2022. Transfer learning-based modified inception model for the diagnosis of Alzheimer's disease. *Frontiers in computational neuroscience.* 16, p.1000435. https://doi.org/10.3389/fncom.2022.1000435.

[128] Sharma, Shagun, Guleria, K., Tiwari, S. ve Kumar, S. 2022. A deep learning based convolutional neural network model with VGG16 feature extractor for the detection of Alzheimer Disease using MRI scans. *Measurement. Sensors. 24*(100506), p.100506. https://doi.org/10.1016/j.measen.2022.100506.

[129] Shastry, K.A., Vijayakumar, V., V, M.K.M., B A, M. ve B N, C. 2022. Deep learning techniques for the effective prediction of Alzheimer's disease: A comprehensive review. *Healthcare (Basel, Switzerland). 10*(10). https://doi.org/10.3390/healthcare10101842.

[130] Shirbandi, K., Khalafi, M., Mirza-Aghazadeh-Attari, M., Tahmasbi, M., Kiani Shahvandi, H., Javanmardi, P. ve Rahim, F. 2021. Accuracy of deep learning model-assisted amyloid positron emission tomography scan in predicting Alzheimer's disease: A Systematic Review and meta-analysis. *Informatics in medicine unlocked. 25*(100710), p.100710. https://doi.org/10.1016/j.imu.2021.100710.

[131] Shorten, C. ve Khoshgoftaar, T. M., 2019, A survey on image data augmentation for deep learning. *Journal of big data, 6*(1), 1-48. https://doi.org/10.1186/s40537-019-0197-0.

[132] Simon, B. C., Baskar, D. ve Jayanthi, V. S, 2019, *Alzheimer's disease classification using deep convolutional neural network. In 2019 9th international conference on advances in computing and communication (ICACC)* (204-208). IEEE.. https://doi.org/10.1109/ICACC48162.2019.8986170.

[133] Simonyan, K., Zisserman, A.K. ve Zisserman, A. 2014. Very deep convnets for large-scale image recognition In: Very deep convnets for large-scale image recognition. *Computing Research Repository*.

[134] Singh, N., Patteshwari, D., Soni, N. ve Kapoor, A. 2023. *Detection of Alzheimer Disease Using MRI Images and Deep Networks-A Review In: International Conference on Advances in IoT and Security with AI. Singapore; Singapore: Springer Nature*, 137–146.. https://doi.org/10.1007/978-981-99-5085-0_15.

[135] SinhaRoy, R. ve Sen, A. 2024. A hybrid deep learning framework to predict Alzheimer's disease progression using generative adversarial networks and deep convolutional neural networks. *Arabian journal for science and engineering. 49*(3), 3267–3284. https://doi.org/10.1007/s13369-023-07973-9.

[136] Sisodia, P.S., Ameta, G.K., Kumar, Y. ve Chaplot, N. 2023. A review of deep transfer learning approaches for class-wise prediction of Alzheimer's disease using MRI images. *Archives of Computational Methods in Engineering. 30*(4), 2409–2429. https://doi.org/10.1007/s11831-022-09870-0.

[137] Song, Y., Xing, H. ve Zhang, Z. 2024. Microvascular perfusion imaging in Alzheimer's disease. *Journal of integrative neuroscience. 23*(4), 70. https://doi.org/10.31083/j.jin2304070.

[138] Suganthe, R.C., Latha, R.S., Geetha, M. ve Sreekanth, G.R. 2020. Diagnosis of Alzheimer's disease from brain magnetic resonance imaging images using deep learning algorithms. *Advances in electrical and computer engineering. 20*(3), 57–64.

[139] Suganyadevi, S., Pershiya, A.S., Balasamy, K., Seethalakshmi, V., Bala, S. ve Arora, K. 2024. Deep Learning Based Alzheimer Disease Diagnosis: A Comprehensive Review. *SN Computer Science. 5*(4). https://doi.org/10.1007/s42979-024-02743-2.

[140] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z. 2016. *Rethinking the inception architecture for computer vision In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).* IEEE.

[141] Tahami Monfared, A.A., Byrnes, M.J., White, L.A. ve Zhang, Q. 2022. Alzheimer's disease: Epidemiology and clinical progression. *Neurology and therapy. 11*(2), pp.553–569. https://doi.org/10.1007/s40120-022-00338-8.

[142] Tanveer, M., Rashid, A.H., Ganaie, M.A., Reza, M., Razzak, I. ve Hua, K.-L. 2022. Classification of Alzheimer's disease using ensemble of deep neural networks trained through transfer learning. *IEEE journal of biomedical and health informatics. 26*(4), 1453–1463. https://doi.org/10.1007/s40120-022-00338-8.

[143] Thamizharasi, M. ve Lakshmi, M. 2022. *Alzheimer's disease detection through Deep learning techniques: A Study In: 2022 1st International Conference on Computational Science and Technology (ICCST).* IEEE. https://doi.org/10.1109/ICCST55948.2022.10040274.

[144] Thangavel, P., Natarajan, Y. ve Sri Preethaa, K.R. 2023. EAD-DNN: Early Alzheimer's disease prediction using deep neural networks. *Biomedical signal processing and control. 86*(105215), p.105215. https://doi.org/10.1016/j.bspc.2023.105215.

[145] Tong, Y., Li, Z., Huang, H., Gao, L., Xu, M. ve Hu, Z. 2024. Research of spatial context convolutional neural networks for early diagnosis of Alzheimer's disease. *The journal of supercomputing. 80*(4), 5279–5297. https://doi.org/10.1007/s11227-023-05655-9.

[146] Tufail, A.B., Ma, Y.-K. ve Zhang, Q.-N. 2020. Binary classification of Alzheimer's disease using sMRI imaging modality and deep learning. *Journal of digital imaging. 33*(5), 1073–1090. https://doi.org/10.1007/s10278-019-00265-5.

[147] Ünlüleblebici, S. 2023. *Derin öğrenme yöntemlerine dayali beyin görüntülerinin analizi ile alzheimer hastalik sınıflandırması.* Erciyes Üniversitesi. Yüksek Lisans Tezi. Kayseri.

[148] Vinze, S., Chodosh, J., Lee, M., Wright, J., ve Borson, S., 2023, The national public health response to Alzheimer's disease and related dementias: Origins, evolution, and recommendations to improve early detection. *Alzheimer's and Dementia, 19*(9), 4276-4286. https://doi.org/10.1002/alz.13376.

[149] Wahlund, L.O. 1996. Magnetic resonance imaging and computed tomography in Alzheimer's disease. Acta neurologica Scandinavica. *Supplementum.* 168, 50–53. https://doi.org/10.1111/j.1600-0404.1996.tb00373.x.

[150] Wang, S.-H., Phillips, P., Sui, Y., Liu, B., Yang, M. ve Cheng, H. 2018. Classification of Alzheimer's disease based on eight-layer convolutional neural network with leaky rectified linear unit and max pooling. *Journal of medical systems. 42*(5), 85. https://doi.org/10.1007/s10916-018-0932-7.

[151] Wang, S.-H., Zhou, Q., Yang, M. ve Zhang, Y.-D. 2021. ADVIAN: Alzheimer's Disease VGG-Inspired Attention Network based on convolutional block attention module and multiple way data augmentation. *Frontiers in aging neuroscience.* 13, p.687456.

[152] Warren, S.L. ve Moustafa, A.A. 2023. Functional magnetic resonance imaging, deep learning, and Alzheimer's disease: A systematic review. *Journal of neuroimaging: official journal of the American Society of Neuroimaging. 33*(1), 5–18. https://doi.org/10.1111/jon.13063.

[153] Wen, J., Thibeau-Sutre, E., Diaz-Melo, M., Samper-González, J., Routier, A., Bottani, S., Dormont, D., Durrleman, S., Burgos, N., Colliot, O. 2022, Alzheimer's Disease Neuroimaging Initiative and Australian Imaging Biomarkers and Lifestyle flagship study of ageing 2020. Convolutional neural networks for classification of Alzheimer's disease: *Overview and reproducible evaluation. Medical image analysis. 63*(101694), p.101694. https://doi.org/10.1515/revneuro-2022-0122.

[154] Westphal, E. ve Seitz, H., 2021, A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. *Additive Manufacturing*, 41, 101965. https://doi.org/10.1016/j.addma.2021.101965.

[155] Wu, L., Rosa-Neto, P. ve Gauthier, S. 2011. Use of biomarkers in clinical trials of Alzheimer disease: from concept to application. *Molecular diagnosis and therapy. 15*(6), pp.313–325.. https://doi.org/10.1007/BF03256467.

[156] Xie, C., Zhuang, X.-X., Niu, Z., Ai, R., Lautrup, S., Zheng, S., Jiang, Y., Han, R., Gupta, T.S., Cao, S., Lagartos-Donate, M.J., Cai, C.-Z., Xie, L.-M., Caponio, D., Wang, W.-W., Schmauck-Medina, T., Zhang, J., Wang, H.-L., Lou, G., Xiao, X., Zheng, W., Palikaras, K., Yang, G., Caldwell, K.A., Caldwell, G.A., Shen, H.-M., Nilsen, H., Lu, J.-H. ve Fang, E.F. 2022. Amelioration of Alzheimer's disease pathology by mitophagy inducers identified via machine learning and a cross-species workflow. *Nature biomedical engineering. 6*(1), 76–93. https://doi.org/10.1038/s41551-021-00819-5.

[157] Yakura, H., Shinozaki, S., Nishimura, R., Oyama, Y. ve Sakuma, J. 2018. *Malware analysis of imaged binary samples by convolutional neural network with attention mechanism In: Proceedings of the Eighth ACM Conference on Data and Application Security and Privacy.* New York, NY, USA: ACM. https://doi.org/10.1145/3176258.3176335.

[158] Yamanakkanavar, N., Choi, J. Y. ve Lee, B., 2020,. MRI segmentation and classification of human brain using deep learning for diagnosis of Alzheimer's disease: a survey. *Sensors, 20*(11), 3243. https://doi.org/10.3390/s20113243.

[159] Yang, D., Martinez, C., Visuña, L., Khandhar, H., Bhatt, C. ve Carretero, J. 2021. Detection and analysis of COVID-19 in medical images using deep learning techniques. *Scientific reports. 11*(1), p.19638. https://doi.org/10.1038/s41598-021-99015-3.

[160] Yingge, H., Ali, I. ve Lee, K.Y. 2020. *Deep neural networks on chip-a survey In: 2020 IEEE International Conference on Big Data and Smart Computing (BigComp).* IEEE, 589–592. https://doi.org/10.1109/BigComp48618.2020.00016.

[161] Yuvaraj, N., Preethi, T., Sumathi, A.C. ve Sri Preethaa, K.R. 2023. *Alzheimer disease classification based on multimodel deep convolutional neural network using MRI images In: AIP conference proceedings.* AIP Publishing.. https://doi.org/10.1063/5.0144082

[162] Zaabi, M., Smaoui, N., Derbel, H. ve Hariri, W. 2020. *Alzheimer's disease detection using convolutional neural networks and transfer learning based methods In: 2020 17th International Multi-Conference on Systems, Signals and Devices (SSD).* IEEE.. https://doi.org/10.1109/SSD49366.2020.9364155.

[163] Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A.K. ve Almotairi, S. 2022. A comparison of pooling methods for convolutional neural networks. *Applied sciences (Basel, Switzerland). 12*(17), p.8643. https://doi.org/10.3390/app12178643.

[164] Zeng, H.-M., Han, H.-B., Zhang, Q.-F. ve Bai, H. 2021. Application of modern neuroimaging technology in the diagnosis and study of Alzheimer's disease. *Neural regeneration research. 16*(1), 73–79. https://doi.org/10.4103/1673-5374.286957.

[165] Zhang, D., Lin, Y., Chen, H., Tian, Z., Yang, X., Tang, J. ve Cheng, K.T. 2022. *Understanding the tricks of deep learning in medical image segmentation: Challenges and future directions. arXiv [cs.CV]*. [Online]. Available from: http://arxiv.org/abs/2209.10307. https://doi.org/10.48550/arXiv.2209.10307.

[166] Zhang, J., Yan, B., Huang, X., Yang, P. ve Huang, C. 2008. *The diagnosis of Alzheimer's disease based on voxel-based morphometry and support vector machine In: 2008 Fourth International Conference on Natural Computation.* IEEE.. https://doi.org/10.1109/ICNC.2008.804.

[167] Zhang, J., Zheng, B., Gao, A., Feng, X., Liang, D. ve Long, X. 2021. A 3D densely connected convolution neural network with connection-wise attention mechanism for Alzheimer's disease classification. *Magnetic resonance imaging.* 78, 119–126. https://doi.org/10.1016/j.mri.2021.02.001.

[168] Zhang, X., Han, L., Zhu, W., Sun, L., ve Zhang, D., 2021, An explainable 3D residual self-attention deep neural network for joint atrophy localization and Alzheimer's disease diagnosis using structural MRI. *IEEE journal of biomedical and health informatics*, *26*(11), 5289-5297. https://doi.org/10.1109/JBHI.2021.3066832.

[169] Zhang, X., Wang, Y., Zhang, N., Xu, D. ve Chen, B. 2019. Research on scene classification method of high-resolution remote sensing images based on RFPNet. *Applied sciences (Basel, Switzerland).* *9*(10), p.2028.. https://doi.org/10.3390/app9102028.

[170] Zhao, Y., Ma, B., Jiang, P., Zeng, D., Wang, X. ve Li, S. 2021. Prediction of Alzheimer's disease progression with multi-information generative adversarial network. *IEEE journal of biomedical and health informatics.* *25*(3), 711–719.. https://doi.org/10.1109/JBHI.2020.3006925.

[171] Zhao, Z., Chuah, J.H., Lai, K.W., Chow, C.-O., Gochoo, M., Dhanalakshmi, S., Wang, N., Bao, W. ve Wu, X. 2023. Conventional machine learning and deep learning in Alzheimer's disease diagnosis using neuroimaging: A review. *Frontiers in computational neuroscience.* 17, p.1038636.. https://doi.org/10.3389/fncom.2023.1038636.

# İNTİHAL RAPORU İLK SAYFASI

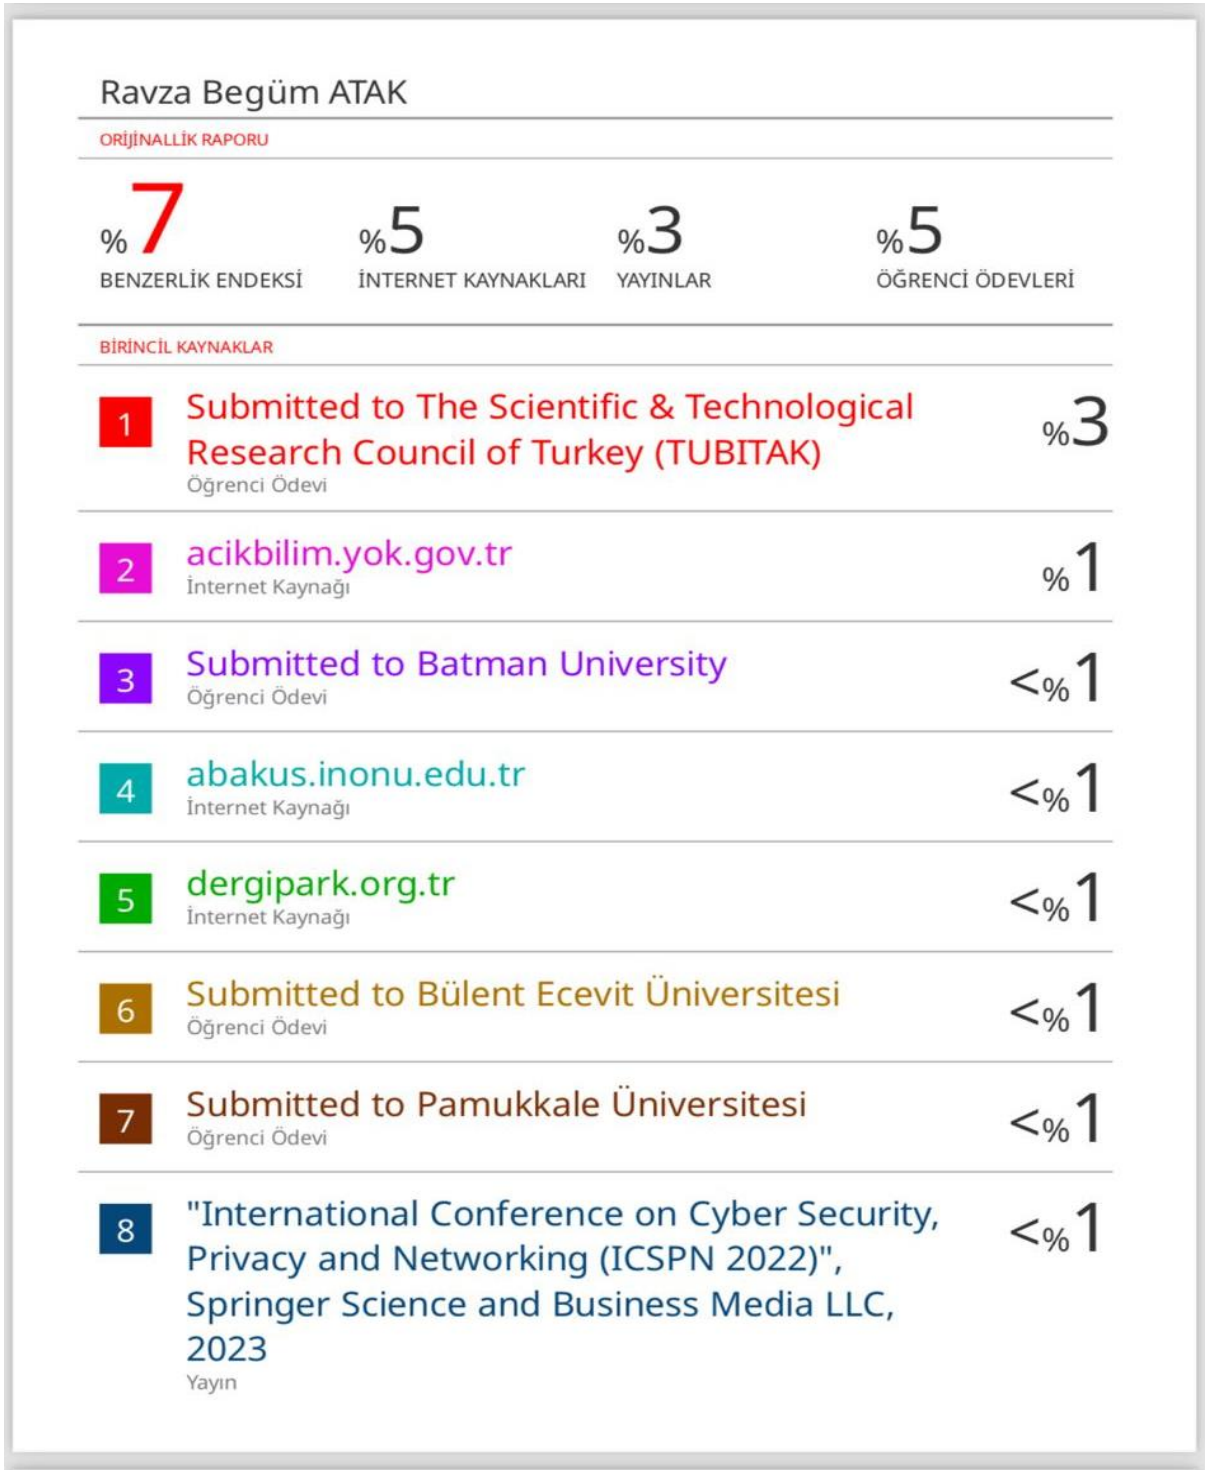

Ravza Begüm ATAK

ORİJİNALLİK RAPORU

| %7 | %5 | %3 | %5 |
|---|---|---|---|
| BENZERLİK ENDEKSİ | İNTERNET KAYNAKLARI | YAYINLAR | ÖĞRENCİ ÖDEVLERİ |

BİRİNCİL KAYNAKLAR

| | | |
|---|---|---|
| 1 | Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK)<br>Öğrenci Ödevi | %3 |
| 2 | acikbilim.yok.gov.tr<br>İnternet Kaynağı | %1 |
| 3 | Submitted to Batman University<br>Öğrenci Ödevi | <%1 |
| 4 | abakus.inonu.edu.tr<br>İnternet Kaynağı | <%1 |
| 5 | dergipark.org.tr<br>İnternet Kaynağı | <%1 |
| 6 | Submitted to Bülent Ecevit Üniversitesi<br>Öğrenci Ödevi | <%1 |
| 7 | Submitted to Pamukkale Üniversitesi<br>Öğrenci Ödevi | <%1 |
| 8 | "International Conference on Cyber Security, Privacy and Networking (ICSPN 2022)", Springer Science and Business Media LLC, 2023<br>Yayın | <%1 |