

T.C.
MALATYA TURGUT ÖZAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DERİN ÖĞRENME YÖNTEMLERİ İLE ALZHEİMER
HASTALIĞININ TESPİTİ VE SINIFLANDIRILMASI

FİRDEVS SÜMEYYE ÇELENLİ

YÜKSEK LİSANS TEZİ
ENFORMATİK ANABİLİM DALI

AĞUSTOS-2024

ONUR SÖZÜ

Sunduđum “Derin Öğrenme Yöntemleri İle Alzheimer Hastalığının Tespiti ve Sınıflandırılması” başlıklı bu tezimde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Firdevs Sümeyye ÇELENLİ



ÖZET

Yüksek Lisans Tezi

Derin Öğrenme Yöntemleri ile Alzheimer Hastalığının Tespiti ve Sınıflandırılması

Firdevs Sümeyye ÇELENLİ

Malatya Turgut Özal Üniversitesi
Lisansüstü Eğitim Enstitüsü
Enformatik Anabilim Dalı

48 + ix sayfa

2024

Danışman: Doç. Dr. Harun Bingöl

Günümüzde yapay zekanın gelişimi ile birlikte derin öğrenme algoritmaları görüntüler üzerinde yapılan çalışmalarda sıklıkla kullanılmaktadır. Görüntüler üzerinde sınıflandırma ve nesne tespiti problemlerinde derin öğrenme algoritmaları yüksek doğruluk oranı sağlamaktadır. Alzheimer hastalığının derin öğrenme algoritmaları kullanılarak hızlı ve yüksek doğruluk oranına sahip modellerin geliştirilmesi Alzheimer hastalığının tespiti için önem arz etmektedir. Alzheimer hastalığı; bilişsel işlevlerde ve günlük yaşam etkinliklerini sürdürme becerilerinde azalma, davranışsal değişimler ve psikiyatrik belirtiler ile karakterize, progresif nörodejeneratif bir hastalıktır. Dünya sağlık örgütü verilerine göre tüm dünyada yaklaşık 55 milyon demans hastası bulunmakta ve bu sayının 2030'da 78 milyona ve 2050'de ise 139 milyona çıkması beklenmektedir. Türkiye'de 600 binden fazla Alzheimer hastası olduğu tahmin edilmektedir. Alzheimer hastalığının tedavisi henüz mümkün değildir. Alzheimer hastalığının doğru teşhisi, özellikle erken aşamada hasta bakımında önemli bir rol oynamaktadır, çünkü ciddiyet ve ilerleme risklerinin bilinci, hastaların geri dönüşü olmayan beyin hasarları şakillenmeden önce önlem almalarını sağlar. Bu tez çalışmasında Alzheimer hastalığının EfficientNetB0, ResNet50, DenseNet201, MobileNetV2 ve InceptionV3 modelleri üzerinde sınıflandırılması gerçekleştirilip, kullanılan modeller üzerinden hibrit model geliştirilmiştir. Deneysel sonuçlar geliştirilen hibrit modelin en başarılı model olduğunu göstermiştir.

ANAHTAR KELİMELER: Alzheimer hastalığı, derin öğrenme, görüntü işleme, yapay zekâ.

ABSTRACT

M.Sc. Thesis

Detection and Classification of Alzheimer's Disease Using Deep Learning Methods

Firdevs Sümeyye ÇELENLİ

Malatya Turgut Ozal University

Graduate School of Education

Department of Informatics

48+ ix pages

2024

Supervisor: Assoc. Prof. Dr. Harun Bingöl

With the advancement of artificial intelligence, deep learning algorithms are frequently used in image-related studies. Deep learning algorithms provide high accuracy rates in image classification and object detection problems. Developing models with high speed and accuracy using deep learning algorithms is crucial for the detection of Alzheimer's disease. Alzheimer's disease is a progressive neurodegenerative disorder characterized by a decline in cognitive functions, the ability to perform daily activities, behavioral changes, and psychiatric symptoms. According to the World Health Organization, there are approximately 55 million dementia patients worldwide, and this number is expected to reach 78 million by 2030 and 139 million by 2050. In Turkey, it is estimated that there are more than 600,000 Alzheimer's patients. Currently, there is no cure for Alzheimer's disease. Accurate diagnosis of Alzheimer's disease, especially in the early stages, plays a significant role in patient care, as awareness of severity and progression risks allows patients to take preventive measures before irreversible brain damage occurs. In this thesis, the classification of Alzheimer's disease was performed using EfficientNetB0, ResNet50, DenseNet201, MobileNetV2, and InceptionV3 models, and a hybrid model was developed based on the used models. Experimental results showed that the developed hybrid model was the most successful one.

KEYWORDS: Alzheimer's disease, deep learning, image processing, artificial intelligence.

TEŐEKKÜR

Yüksek lisans tezimin hazırlanma süresince bilgi, deneyim ve becerileriyle beni her zaman yönlendiren, desteklerini hiçbir zaman esirgemeyen kıymetli danışman hocam Doç. Dr. Harun Bingöl'e, her daim yanımda olan değerli aileme, sabır ve anlayışlarıyla takıldığım her konuda yardımcı olmaya çalışan benden yardımlarını ve ilgisini esirgemeyen, her zaman desteğini hissettiren, eşim Halil İbrahim Çelenli'ye teşekkür ederim.



İÇİNDEKİLER

ONUR SÖZÜ	i
ÖZET	ii
ABSTRACT	iii
TEŞEKKÜR	iv
İÇİNDEKİLER	v
SİMGELER VE KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi	1
1.2. Tezin Organizasyonu	1
2. KAYNAK ÖZETLERİ	3
2.1. Tezin Literatüre Katkısı	5
3. MATERYAL VE METOT	6
3.1. Alzheimer Hatalığı ve Görüntüleme Teknolojileri	6
3.2. Yapay Zeka	10
3.2.1. Makine Öğrenmesi	11
3.2.2. Derin Öğrenme	12
3.3. Makine Öğrenmesi Algoritmaları ve Veri Çoğaltma Tekniği	13
3.3.1. Destek Vektör Makineleri (SVM)	13
3.3.2. K-En Yakın Komşu (KNN)	13
3.3.3. Karar Ağaçları	14
3.3.4. Lojistik Regresyon	14
3.3.5. Rastgele Orman	15
3.3.6. Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE)	15
3.4. Derin Öğrenme Mimarileri	15
3.4.1. Evrişimsel Sinir Ağları (CNN)	16
3.4.2. Tekrarlayan Sinir Ağı (RNN)	17
3.4.3. Çekişmeli Üretici Ağ (GAN)	18
3.4.4. Uzun Kısa Süreli Bellek (LSTM)	19
3.5. Derin Öğrenme Katmanları	19
3.5.1. Giriş (Input) Katmanı	19
3.5.2. Evrişim Katmanı	20
3.5.3. Aktivasyon (ReLU) Katmanı	21
3.5.4. Havuzlama (Pooling) Katmanı	21
3.5.5. Tam Bağlı (Full-Connected) Katman	22
3.5.6. Dropout katmanı	23
3.5.7. Sınıflandırma (Classification) Katmanı	24
3.5.8. Yumuşatma (Softmax) Katmanı	24
3.6. CNN Algoritmaları	25
3.6.1. DenseNet	25
3.6.2. MobileNet	25
3.6.3. ResNet	26
3.6.4. EfficientNet	27
3.6.5. Inception	28
3.7. Derin Öğrenme Kütüphaneleri	29
3.7.1. TensorFlow	29

3.7.2. Caffe, Caffe2	29
3.7.3. Theano	29
3.7.4. Torch	30
3.8. Derin Öğrenme Uygulamaları	30
3.8.1. Görüntü/Video işleme	30
3.9. Önerilen Derin Öğrenme Tabanlı Hibrit Yöntem	32
3.9.1. Veri Kümesinin Tespiti ve Oluşum Aşamaları	33
3.9.2. Sonuçların Toplanması ve Değerlendirme Aşaması	33
4. ARAŞTIRMA BULGULARI	35
4.1. Veri Kümesinin Derin Öğrenme Mimarileriyle Başarımı ve Sonuçları.....	35
4.1.1. Hibrit Model Oluşturulması ve Başarımı	38
4.2. Tartışma.....	40
5. SONUÇ VE ÖNERİLER	41
6. KAYNAKLAR.....	43



SİMGELER VE KISALTMALAR DİZİNİ

CNN	: Evrişimsel Sinir Ağları
MRG	: Manyetik Rezonans Görüntüleme
SVM	: Destek Vektör Makineleri
KNN	: K-En Yakın Komşu
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği
İVM	: İç Vektör Makineleri
AÖM	: Aşırı Öğrenme Makinesi
MCI	: Hafif Bilişsel Bozukluk
PET	: Pozitron Emisyon Tomografisi
YSA	: Yapay Sinir Ağları
LSTM	: Uzun Kısa Süreli Bellek
RNN	: Tekrarlayan Sinir Ağı
GAN	: Çekişmeli Üretici Ağı
GPU	: Grafik İşleme Birim
NLP	: Doğal Dil İşleme
CT	: Bilgisayarlı Tomografi
EKG	: Elektrokardiyogram
EEG	: Elektroensefalografi
SWE	: Kesme Dalga Elastografisi
TP	: Doğru Pozitif
FN	: Yanlış Negatif
TN	: Doğru Negatif
FP	: Yanlış Pozitif

ŞEKİLLER DİZİNİ

Şekil 3.1. Manyetik Rezonans Görüntüleme ve Örnek Beyin MRG Resmi	9
Şekil 3.2. Beyin PET Resmi ve Göz Retina Resmi	9
Şekil 3.3. Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenmenin Küme İlişkisi	11
Şekil 3.4. Derin Öğrenme Modeli	13
Şekil 3.5. CNN Mimarisi	17
Şekil 3.6. RNN Mimarisi	18
Şekil 3.7. GAN Mimarisi	18
Şekil 3.8. Evrişim İşlemi ile Çıktı Matrisi	20
Şekil 3.9. ReLU İşlevi	21
Şekil 3.10. Havuzlama İşlem Örneği	22
Şekil 3.11. Tam Bağlı Katman	23
Şekil 3.12. (A) Çok Katmanlı Yapay Sinir Ağ Örneği (B) Dropout İşlemi Uygulanmış Sinir Ağ Örneği	24
Şekil 3.13. ResNet50 Modeli	27
Şekil 3.14. EfficientNetBO Modeli	28
Şekil 3.15. Önerilen Modelin İş Akış Diyagramı	32
Şekil 4.1. Örnek Veriler	35
Şekil 4.2. Hibrit SVM Karışıklık Matrisi	39

ÇİZELGELER DİZİNİ

Çizelge 3.1. Karışıklık Matrisinin Analizinde Kullanılan Metrikler.....	34
Çizelge 4.1. Temel Veri Etiket Dağılımları	35
Çizelge 4.2. Temel Model Sonuçları.....	36
Çizelge 4.3. SMOTE Veri Etiket Dağılımları	36
Çizelge 4.4. SMOTE Temel Model Sonuçları	36
Çizelge 4.5. SVM Sonuçları.....	37
Çizelge 4.6. KNN Sonuçları.....	37
Çizelge 4.7. Karar Ağaçları Sonuçları.....	37
Çizelge 4.8. Lojistik Regresyon Sonuçları	38
Çizelge 4.9. Rastgele Orman Sonuçları.....	38
Çizelge 4.10. Hibrit Model Sonuçları	39



1. GİRİŞ

Günümüz mühendislik uygulamalarında insan gibi düşünen, insan gibi davranışlar sergileyen uygulamalara ağırlık verilmektedir. İnsan olgusunun mühendislik uygulamalarında yer alması için kullanılan adlandırma makine öğrenmesi olarak bilinir [1,2]. İnsanın hayatı boyunca öğrendiği şeylerin günlük yaşamda hayatını kolaylaştırdığı ve deneyimlerine göre hareket ettiğini örnek alarak aynı şekilde makine öğrenmesi gerçekleştirilmeye çalışılmaktadır.

Güvenlik uygulamalarında, sınıflandırma, medikal teşhis ve tanı uygulamalarında, ileriye dönük tahminsel yaklaşımlarda kullanımı artmakta ve hayatı kolaylaştırmaktadır [3, 4]. Bu gibi uygulamaların gerçekleştirilmesi için kullanılan derin öğrenmedeki temel nokta insan beynindeki nöronların çalışmasından faydalanılarak benzer bir yaklaşımla makinanın öğrenmesini ve buna göre davranmasını sağlamaktır [5]. İnsan beynindeki sinir hücrelerinin çalışma mantığından faydalanılarak yapay sinir hücre modeli oluşturulmuştur. Bu yapay sinir hücre modeli zaman içerisinde geliştirilmiş ve makine öğrenmesinde sıklıkla kullanılmaya başlanmıştır. Günümüzde bu yapay sinir hücre mantığı daha ileri seviyelere taşınarak derin öğrenme mantıklı bir model kullanılmaya başlanmıştır [6].

1.1. Tezin Amacı ve Önemi

Bu tez de derin öğrenme kavramı ve derin öğrenme mimarileri hakkında detaylı bilgiler verilmiştir. Derin öğrenme ile görüntü işlemenin önemiyle birlikte insan sağlığına etkisi, Alzheimer hastalığının sınıflandırılması ve tespiti vurgulanmış olup, yeni bir hibrit model önerilmiştir. Önerilen hibrit model, derin öğrenme modelleri ile karşılaştırılmıştır.

1.2. Tezin Organizasyonu

Tezin organizasyonu, Alzheimer hastalığının tespiti ve sınıflandırılması üzerine odaklanan dört ana bölümden oluşmaktadır: Giriş bölümünde tezin amacı, önemi ve araştırma soruları tanımlanmış, kaynak özetleri başlığı altında Alzheimer hastalığının tespiti ve sınıflandırılması ile ilgili mevcut çalışmalar detaylıca incelenmiş ve bu bölüm, tezin konusunun literatüre olan katkısını ortaya koymuştur. Materyal ve Metotlar bölümünde, kullanılan yöntemler, materyaller ve Alzheimer hastalığını tespit etmek için kullanılan yapay zeka ve derin öğrenme teknikleri ile ilgili algoritmalar açıklanmıştır. Araştırma Bulguları bölümünde tez çalışmasında kullanılan veri kümesi

ve modeller açıklanıp sonuçlar çıkarılmıştır. Sonuç ve Öneriler bölümünde ise araştırma bulguları ve elde edilen sonuçlar değerlendirilmiş, ileriye dönük önerilerde bulunulmuştur. Bu yapısal organizasyon, konunun kapsamlı bir şekilde ele alınmasını sağlamakta ve okuyucuya konu hakkında derinlemesine bilgi sunmaktadır.



2. KAYNAK ÖZETLERİ

Alzheimer yaygın bir hastalık olduğundan ve tedavisi zor olduğundan Literatürde bu konuda uzmanlar tarafından teşhis konulan çok sayıda çalışma bulunmaktadır.

Liu vd [7] yaptıkları çalışmada Alzheimer verilerini kullanarak sınıflandırma işlemini gerçekleştirmişlerdir. DenseNet modelini sınıflandırma problemi üzerinden kullanarak çıktı katmanında softmax aktivasyon fonksiyonuyla %88.9 doğruluk oranı elde etmişlerdir.

Yıldırım vd [8] yaptıkları çalışmada 4 sınıflı bir veri seti kullanarak Alzheimer hastalığını sınıflandırmışlardır. Çalışmalarında, Evrişimsel Sinir Ağları (CNN) modellerinden sonuçlar elde etmişlerdir. Bu sonuçları önerdikleri hibrit modelle karşılaştırıp, modellerinin temeli olarak ResNet50'yi kullandıklarını ve bu modelin bilgisinden yararlandıklarını belirtmişlerdir. Hibrit modellerinde elde ettikleri doğruluk oranı %90 olmuştur. Ayrıca önceden eğitilmiş CNN modellerinde elde edilen başarı oranının önerilen hibrit modele göre daha düşük olduğunu belirtmişlerdir.

Farooq vd [9] Manyetik Rezonans Görüntüleme (MRG) verisi kullanarak yaptıkları çalışmada 4 sınıflı bir veri seti kullanmışlardır. Araştırmacılar yaptıkları çalışmada ESA modelleri olan GoogleNet, ResNet18 ve ResNet152 mimarilerini kullanmışlardır. Bu mimariler literatürde kabul görse de bunları temel alarak farklı hibrit modellerde geliştirmek mümkündür. Yaptıkları çalışmada en yüksek doğruluk değeri GoogleNet modelinde %98.88 ile elde edilmiştir.

Lama vd [10] Alzheimer MRG verisini makine öğrenmesi arasında yer alan sınıflandırıcı yöntemlerden Destek Vektör Makineleri (SVM), İç Vektör Makineleri (İVM) ve Aşırı Öğrenme Makinesi (AÖM) kullandılar. Onlar SVM sınıflandırıcısında %75.33, İVM sınıflandırıcısında %60,2 ve AÖM'de %76,61 sınıflandırıcısından doğruluk oranı elde etmişlerdir.

Qui vd [11] Alzheimer hastalığının demans değerlendirmesi için multimodal derin öğrenme yöntemlerini kullanarak, MRG ve klinik verilerin birleşiminden oluşan bir model geliştirmiştir. Bu çalışma, farklı veri türlerinin entegrasyonunun hastalık evrelerinin daha doğru bir şekilde sınıflandırılmasına katkıda bulunduğunu göstermiştir.

Park vd [12] Alzheimer hastalığının sınıflandırılması için 18F-flortaucipir (AV-1451) tau PET görüntüleri kullanarak derin öğrenme uygulamalarını incelemiştir. Bu araştırma, 2D CNN-LSTM ve 3D CNN modellerinin yüksek performans sergilediğini ve multimodal veri entegrasyonunun tanı doğruluğunu artırdığını vurgulamaktadır.

Smith vd [13] Alzheimer hastalığının sınıflandırılması için farklı CNN modellerini karşılaştırarak, derin öğrenme modellerinin tıbbi görüntü analizindeki rolünü araştırmıştır. Çalışma, çeşitli CNN modellerinin performanslarını değerlendirerek, en uygun mimarinin seçilmesine yönelik önerilerde bulunmuştur.

Doe vd [14] MRG taramalarını kullanarak Alzheimer hastalığının teşhisi için hibrit derin öğrenme modelleri geliştirmiştir. Bu çalışmada, SVM sınıflandırıcısının hibrit yapılar içinde etkin bir şekilde kullanılması ve standart derin öğrenme modellerine kıyasla daha iyi performans göstermesi incelenmiştir.

Wang vd [15] Alzheimer hastalığı tanısı için derin öğrenme tabanlı multimodal füzyon yöntemini araştırmışlardır. Çalışma, çeşitli veri türlerinin birleştirilmesinin tanı doğruluğunu artırdığını göstermiştir.

Chen vd [16] Alzheimer hastalığının erken teşhisi için yapısal MRG verilerini kullanan geliştirilmiş bir derin öğrenme yaklaşımı sunmuştur. Bu çalışma, modelin erken evre Alzheimer tanısında yüksek hassasiyet ve doğruluk sağladığını ortaya koymuştur.

Patel vd [17] Alzheimer hastalığının tespiti için transfer öğrenimi ve konvolüsyonel sinir ağlarını kullanarak yeni bir yöntem geliştirmişlerdir. Çalışma, transfer öğreniminin sınırlı veri setleriyle bile yüksek performans elde edebileceğini göstermiştir.

Zhang vd [18] Alzheimer hastalığının sınıflandırılması için çok ölçekli özellik füzyonunu kullanan bir derin öğrenme modeli geliştirmişlerdir. Çalışma, farklı ölçeklerdeki özelliklerin birleşiminin tanı performansını önemli ölçüde artırdığını göstermiştir.

Liv vd [19] Alzheimer hastalığının sınıflandırılması için ensemble derin öğrenme yöntemlerini incelemiştir. Çalışma, birden fazla modelin birleştirilmesinin tanı doğruluğunu ve güvenilirliğini artırdığını göstermektedir.

Gonzalez vd [20] Alzheimer hastalığının teşhisi için grafik konvolüsyonel ağlar (GCN) kullanan yenilikçi bir yöntem sunmuşlardır. Bu çalışma, GCN'nin beyin ağ yapılarının analizinde yüksek doğruluk ve verimlilik sağladığını ortaya koymuştur.

2.1. Tezin Literatüre Katkısı

Kaynak özetleri bölümünde tez kapsamında ele alınan konu başlıklarıyla ilgili literatüre değinilmiş ve derin öğrenme algoritmaları ile Alzheimer hastalığının tespitine yönelik çalışmalardan bahsedilmiştir. Bu çalışmalardaki başarı oranının artması hastalık tespitinde derin öğrenme tabanlı yöntemlerin kullanım alanını arttırmaktadır. Tez kapsamında ise derin öğrenme algoritmalarıyla yeni bir hibrit model önerilerek daha başarılı sonuçlar elde edilmiştir. Önerilen yöntemle hem tıp hem de bilim dünyası adına yüksek doğrulukla hastalık tespiti amaçlanmıştır.

3. MATERYAL VE METOT

Bu bölümde temel olarak Alzheimer hastalığının derin öğrenme algoritmaları ile tespit edilme tekniğinin değerlendirilmesine odaklanmaktadır. Bugüne kadar bu alanda birçok çalışma yapılmış, birçok yeni teknoloji kullanılmış ve geliştirilmiştir. İleri teknoloji ile uygulanan görüntü işleme algoritmaları sayesinde Alzheimer hastalığının tespiti hız kazanmıştır. Bu bölümde, Alzheimer hastalığının tanımı ve yapay zeka, derin öğrenme ve görüntü işleme algoritmalarının teorik anlatımı yapılmıştır.

3.1. Alzheimer Hastalığı ve Görüntüleme Teknolojileri

Alzheimer hastalığı, genellikle 65 yaş üzerindeki insanlarda görülen, ilerleyici bir beyin hastalığıdır. Bu hastalık, bellek kaybı, düşünme yeteneğinde azalma ve diğer zihinsel işlevlerde bozulmalarla karakterizedir. Alzheimer hastalığı, beyindeki sinir hücrelerinin ölümüne neden olan ve beyindeki ağ bağlantılarını ve nörotransmitterleri etkileyen bir protein birikimi ile ilişkilidir. Bu protein birikimi, amiloid plağın oluşmasına ve nörofibril yumaklarının beyinde birikmesine neden olur. Alzheimer hastalığının semptomları yavaş yavaş başlar ve zamanla kötüleşir. İlk semptomlar genellikle bellek sorunlarıdır. Hastalar, yeni bilgileri öğrenmekte zorlanır ve öğrenilen bilgileri hatırlamakta zorlanır. Hastalık ilerledikçe, konuşma, düşünme, planlama ve diğer bilişsel işlevlerdeki sorunlar artar. Hasta, tanıdık kişileri tanımakta güçlük çeker ve hatta en basit günlük aktiviteleri bile yapmakta zorlanabilir. Alzheimer hastalığına tam olarak neyin neden olduğu bilinmemektedir. Ancak, yaş, genetik faktörler ve beyindeki hasarlar ve iltihaplanma gibi faktörlerin rol oynadığı düşünülmektedir. Bu hastalık, hafıza kaybı, düşünme ve davranışlarda değişiklik, bilişsel bozukluklar ve kişilik değişiklikleri gibi semptomlara neden olur. Alzheimer hastalığı genellikle ileri yaşlarda ortaya çıkar ve yaşlı popülasyonda en yaygın nedenlerden biridir. Alzheimer hastalığının nedeni tam olarak bilinmemektedir, ancak genetik faktörlerin yanı sıra yaşam tarzı faktörleri ve çevresel faktörlerin de rol oynadığı düşünülmektedir. Alzheimer hastalığı olan kişilerin beyinde, özellikle hafıza, öğrenme ve düşünme ile ilgili bölgelerde, beyin hücrelerinin ölümüne neden olan beta amiloid adı verilen plaklar ve nörofibril adı verilen protein demetleri birikir. Alzheimer hastalığının teşhisi, genellikle bilişsel testler ve beyin görüntüleme çalışmaları gibi yöntemler kullanılarak yapılır. Tedavisi henüz bulunamamıştır, ancak semptomları hafifletmek için ilaçlar ve destekleyici tedaviler kullanılabilir. Ayrıca, düzenli egzersiz yapmak,

zihinsel egzersizler yapmak, sağlıklı bir diyet ve sosyal bağlantılar gibi yaşam tarzı değişiklikleri, Alzheimer hastalığı riskini azaltmaya yardımcı olabilir [21].

Alzheimer hastalığı, beyin hücrelerinin yavaş yavaş ölmesi ve beynin işlevselliğini kaybetmesi sonucu ortaya çıkan ilerleyici bir hastalıktır. Bu hastalık, genellikle yaşlı insanlarda görülür ve hafıza kaybı, düşük konsantrasyon, zayıf karar verme ve diğer zihinsel işlevlerde bozulma gibi semptomlarla kendini gösterir. Derin öğrenme, makine öğrenmesinin bir alt dalıdır ve büyük veri setlerinin incelenmesi ve model oluşturulması için kullanılır. Bu teknoloji, beynin çalışma şekline esinlenilerek geliştirilmiştir. Derin öğrenme, Alzheimer hastalığı için potansiyel bir teşhis aracı olarak kullanılabilir. Örneğin, beyin tarama görüntülerinin derin öğrenme yöntemleriyle incelenmesi, Alzheimer hastalığının erken teşhisinde yardımcı olabilir. Ayrıca, hastalığın ilerleyişini izlemek ve tedavi etkilerini değerlendirmek için de kullanılabilir. Derin öğrenme yöntemleri, beyin görüntülerindeki küçük değişiklikleri tanımlamak ve bunları hastalıkla ilişkilendirmek için kullanılıyor. Bu nedenle, derin öğrenme, Alzheimer hastalığının teşhisi ve tedavisi için potansiyel bir araç olarak kullanılabilir. Ancak, hastalığın ilerlemesini durdurmak veya geri çevirmek için henüz etkili bir tedavi yoktur, bu nedenle erken teşhis ve yönetim, hastalığın seyrini yavaşlatmak için en önemli faktördür. Derin öğrenme yöntemleri, Alzheimer hastalığının erken teşhisi ve tedavisi konusunda da umut verici sonuçlar verebilir. Alzheimer hastalığı, beyindeki sinir hücreleri arasındaki iletişimdeki bozulmalar ve hücre ölümleri sonucu oluşan bir nörodejeneratif hastalıktır. Bu hastalığın belirtileri genellikle ilerleyici hafıza kaybı, bilişsel bozukluklar ve nihayetinde yaşam fonksiyonlarının kaybıdır. Ancak, hastalığın erken dönemlerinde teşhis edilmesi ve tedaviye başlanması hastalığın ilerlemesini yavaşlatabilir veya durdurabilir. Derin öğrenme, bu hastalığın erken teşhisinde ve tedavisinde kullanılacak birçok yöntem sunuyor. Örneğin, MRG görüntüleri ile derin öğrenme teknikleri kullanılarak Alzheimer hastalığının erken dönemlerinde teşhis edilebiliyor. Ayrıca, hastalığın ilerlemesini takip etmek ve tedaviye yanıtı ölçmek için beyin aktivitesi ölçümleri de kullanılabilir. Derin öğrenme teknikleri ayrıca, Alzheimer hastalığına sahip hastaların yaşam kalitesini artırmak için kullanılabilir. Örneğin, hasta bakımı sırasında robotların kullanılması, hastaların günlük aktivitelerini takip etmek ve bu aktiviteleri desteklemek için derin öğrenme algoritmaları kullanılabilir. Ayrıca, konuşma tanıma

ve doğal dil işleme teknikleri de Alzheimer hastalarının konuşmalarını ve davranışlarını anlamak ve onlara uygun bir şekilde yanıt vermek için kullanılabilir.

Derin öğrenme teknikleri, Alzheimer hastalığının erken teşhisinde, tedavisinde ve hasta bakımında önemli bir rol oynayabilir. Ancak, bu tekniklerin klinik kullanımı henüz yeni başlamıştır ve daha fazla araştırma ve geliştirme çalışmalarına ihtiyaç duyulmaktadır.

Görüntü işleme, Alzheimer hastalığının tespiti için kullanılan yaygın bir yöntemdir. Görüntü işleme, beyindeki bu kayıpları tespit etmek için farklı yöntemler kullanılabilir. Beyin MRG görüntüleri, Alzheimer hastalığının teşhisi ve ilerlemesi için kullanılan yaygın bir görüntüleme yöntemidir. Beyin MRG görüntüleri, beyin 3 boyutlu bir görüntüsünü elde etmek için manyetik alanlar ve radyo dalgaları kullanır. Görüntü işleme teknikleri, beyin MRG görüntülerini analiz ederek Alzheimer hastalığının teşhisinde kullanılabilen farklı özellikleri ortaya çıkarabilir.


Beyin MRG görüntüleri: görüntüleri, beyin dokusunun kesitsel görüntüsünü oluşturmak için manyetik alanlar kullanır. Bu görüntüler, beyin yapısındaki değişiklikleri göstererek Alzheimer hastalığının erken teşhisinde yardımcı olabilir. Şekil 3.1’de MRG makinesi ve örnek resmi gösterilmiştir.

PET Görüntüleri: Alzheimer hastalığının teşhisi için kullanılan bir diğer görüntüleme tekniğidir. PET, vücutta radyoaktif bir madde enjekte edilerek alınan görüntüler sayesinde beyin aktivitesinin ölçülmesine yardımcı olur. Bu yöntem, beyindeki protein birikimi gibi Alzheimer hastalığının belirtilerini gösteren faktörleri tespit etmek için kullanılır.

Retina Görüntüleri: Alzheimer hastalığının teşhisi için yeni bir yöntem olarak kullanılmaktadır. Retina, gözün arka tarafında bulunan ışığı algılayan dokudur. Bazı çalışmalar, Alzheimer hastalığı olan kişilerde retina dokusunda değişiklikler olduğunu göstermektedir. Bu nedenle, retina görüntüleri Alzheimer hastalığının erken teşhisinde kullanılabilir. Şekil 3.2’de beyin PET ve göz retina görüntüsü gösterilmiştir.



Şekil 3.1. Manyetik Rezonans Görüntüleme ve Örnek Beyin MRG Resmi



Şekil 3.2. Beyin PET Resmi ve Göz Retina Resmi

Örneğin, beyin MRG görüntülerindeki gri madde hacmi, beyindeki sinir hücrelerinin kaybının bir göstergesi olarak kullanılabilir. Görüntü işleme teknikleri, MRG görüntülerindeki gri madde hacmini ölçebilir ve bu ölçümleri Alzheimer hastalığı tanısı ve ilerlemesi hakkında bilgi sağlamak için kullanabilir. Beyin MRG görüntüleri ayrıca, Alzheimer hastalığının beyindeki belirli bölgelerdeki sinir hücrelerindeki kaybı gösteren beyin hasarı paternlerini tespit etmek için de kullanılabilir. Görüntü işleme teknikleri, beyin MRG görüntülerindeki bu hasar paternlerini tespit edebilir ve bu bilgileri Alzheimer hastalığının ilerlemesi hakkında bilgi sağlamak için kullanabilir. Son zamanlarda, derin öğrenme teknikleri de Alzheimer hastalığının teşhisinde ve ilerlemesinin takibinde kullanılmaya başlanmıştır.

Derin öğrenme, çok katmanlı sinir ağları kullanarak verilerden otomatik olarak özellikler öğrenen bir makine öğrenme tekniğidir. Örneğin, Derin öğrenme üzerinde bulunan CNN yöntemi, beyin MRG görüntüleri kullanılarak Alzheimer hastalığının tespiti için kullanılabilir. CNN yöntemi, beyin MRG görüntülerindeki farklı yapıları

öğrenerek, Alzheimer hastalığının özelliklerini otomatik olarak tespit edebilir. Görüntü işleme teknikleri ve derin öğrenme yöntemleri, Alzheimer hastalığının tespiti ve ilerlemesi hakkında bilgi sağlamak için kullanılan güçlü araçlardır. Bu teknolojilerin geliştirilmesi, Alzheimer hastalığının daha erken teşhis edilmesine ve elde edilen öznitelikler, makine öğrenmesi veya derin öğrenme algoritmaları kullanılarak eğitilmiş bir sınıflandırıcı modeline beslenir ve bu model, görüntünün Alzheimer hastalığına sahip olup olmadığını tahmin eder.

MRG veya PET görüntüleri gibi beyin görüntüleri kullanılarak, hastalığın erken teşhisi için özellikler çıkarılır. Bu özellikler daha sonra makine öğrenimi algoritmalarına beslenerek hastalığın teşhisi için bir model oluşturulur. Bu yöntem, daha hızlı ve daha hassas teşhisler sağlayabilir.

Görüntü işleme teknikleri ve makine öğrenimi algoritmaları, Alzheimer hastalığının erken teşhisi için umut verici yöntemlerdir. Ancak, bu yöntemlerin klinik kullanımı hala sınırlıdır ve daha fazla araştırmaya ihtiyaç vardır.

3.2. Yapay Zeka

Yapay zeka, insan zekasını taklit etmeye çalışan bilgisayar sistemlerinin tasarlanması ve geliştirilmesi sürecidir. Yapay zeka uygulamaları genellikle belirli bir amaca hizmet eden algoritmalar ve modellemeler kullanılarak oluşturulur. Örneğin, bir yüz tanıma uygulaması yapmak için, belirli bir yüz tanıma algoritması kullanılır. Derin öğrenme algoritmaları yapay zekanın bir alt dalı olup, yapay sinir ağları gibi karmaşık yapay zeka modellerinin tasarlanmasını ve eğitimini içeren bir yöntemdir. Derin öğrenme yöntemleri, büyük veri setleri üzerinde çalışır ve bu veri setlerini analiz ederek belirli bir görevi yerine getirecek algoritmalar öğrenir. Derin öğrenme modeli oluşturmak için, genellikle çok sayıda katmanı olan yapay sinir ağları kullanılır. Derin öğrenme uygulamaları arasında görüntü tanıma, ses tanıma, doğal dil işleme, robotik gibi alanlar bulunur. Bu uygulamalar, özellikle son yıllarda geliştirilen derin öğrenme algoritmaları sayesinde büyük bir ivme kazanmıştır.

Yapay zeka, bir bilgisayar sisteminin insanların yapabildiği gibi çeşitli görevleri yerine getirmesi için tasarlanmış bir teknolojidir. Yapay zeka, farklı verileri analiz etmek, öğrenmek ve sonuçlarını tahmin etmek için kullanılabilir. Makine öğrenmesi ve derin öğrenme, yapay zeka teknolojilerinin alt kategorileridir. Makine öğrenmesi, bir bilgisayarın bir görevi öğrenmesi için verilerle eğitilmesi sürecidir.

Makine öğrenmesi algoritmaları, verileri analiz ederek trendleri ve kalıpları belirler ve bu kalıpları kullanarak gelecekteki sonuçları tahmin eder. Makine öğrenmesi, doğal dil işleme, görüntü işleme ve diğer alanlarda kullanılabilir. Derin öğrenme, yapay sinir ağları gibi çok katmanlı algoritmalar kullanarak makine öğrenmesi modelleri oluşturur. Derin öğrenme, büyük miktarda veriyi işleyerek sonuçları tahmin etmek için kullanılır. Özellikle görüntü ve ses işleme, doğal dil işleme ve oyun stratejileri gibi alanlarda başarılı sonuçlar verir. Derin öğrenme, birçok farklı alanlarda kullanılabilir. Örneğin, sağlık sektöründe, hastaların teşhis ve tedavi süreçlerini iyileştirmek için derin öğrenme teknikleri kullanılabilir. Ayrıca, otomotiv endüstrisinde de derin öğrenme, sürüş yardım sistemleri ve otonom araç teknolojilerinin geliştirilmesinde kullanılabilir. Yapay zeka ve derin öğrenme, günümüzde birçok endüstride büyük bir etkiye sahiptir ve gelecekte daha da yaygınlaşması beklenmektedir. Şekil 3.3’de yapay zeka, makine öğrenmesi ve derin öğrenme arasındaki küme ilişkisi gösterilmiştir.



Şekil 3.3. Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenmenin Küme İlişkisi

3.2.1. Makine Öğrenmesi

Makine öğrenmesi, makine zekâsını geliştirmek için matematiksel modellere dayanan bir yapay zekâ alt sınıfıdır. Makine öğrenmesi çalışmalarında ele alınan problemi çözmek amacıyla programlamadan herhangi bir test örneği için tahminleri otomatik olarak üreten bir modeli oluşturulur ve belirli bir veri kümesi üzerinde eğitilir.

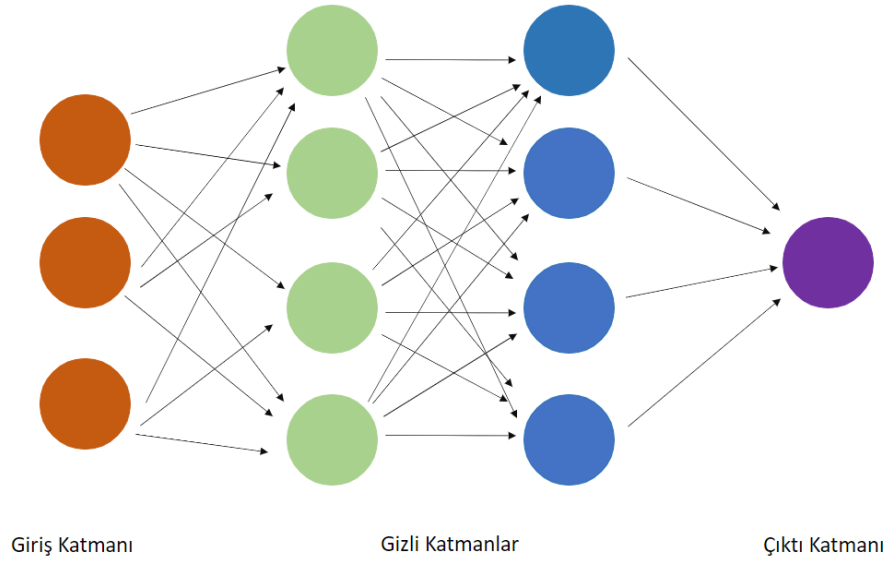
3.2.2. Derin Öğrenme

Derin öğrenme, makine öğrenmesinin bir alt dalıdır ve özellikle çok katmanlı yapay sinir ağları (YSA) kullanılarak karmaşık veri yapılarını öğrenme yeteneğine sahiptir. Geleneksel makine öğrenme yöntemlerinden farklı olarak, derin öğrenme algoritmaları büyük veri setleri üzerinde çalışarak, verinin ham halinden özellikleri otomatik olarak çıkarabilir ve sınıflandırma, tahmin gibi görevleri daha yüksek doğrulukla gerçekleştirebilir. Bu teknolojinin arkasındaki temel prensip, insan beyninin çalışma şeklini taklit eden çok katmanlı sinir ağlarıdır. Her katman, önceki katmandan aldığı veriyi işler ve daha soyut ve anlamlı bir temsilini oluşturur. Bu sayede, derin öğrenme, görüntü tanıma, doğal dil işleme ve ses tanıma gibi karmaşık görevlerde üstün başarılar elde etmiştir.

Derin öğrenmenin kullanıldığı alanlar oldukça geniştir. Görüntü işleme alanında, nesne tanıma ve sınıflandırma, yüz tanıma ve tıbbi görüntü analizi gibi uygulamalarda yaygın olarak kullanılır. Örneğin, sağlık sektöründe MRG ve PET taramalarındaki anomalilerin tespiti için derin öğrenme algoritmaları kullanılmaktadır. Doğal dil işleme (NLP) alanında, metin analizi, duygu analizi, makine çevirisi ve sohbet robotları gibi uygulamalar için derin öğrenme modelleri geliştirilmektedir. Ses tanıma teknolojilerinde, konuşma tanıma ve konuşma sentezi gibi görevlerde derin öğrenme kullanımı oldukça yaygındır. Ayrıca, otonom araçlar, finansal analizler, biyoinformatik ve oyun geliştirme gibi birçok farklı sektörde de derin öğrenme teknikleri uygulanmaktadır. Bu alanlardaki başarılar, derin öğrenmenin sunduğu yüksek doğruluk ve performans sayesinde mümkün olmaktadır.

Derin öğrenme, çok katmanlı yapay sinir ağları kullanılmaktadır. Örneğin bir resim tanıma işlemi ele alalım. Giriş katmanında bir görüntü piksel olarak ele alınır. Ardından gizli katmanlar, giriş katmanından gelen veriyi işleyip daha anlamlı hale getirir. Katmanlar arası geçişte, görüntü detayları daha iyi öğrenilmiş olur. Son olarak çıkış katmanında, görüntünün tanınıp tanınmadığı bilgisi belirtilir.

Şekil 3.4’de temsili derin öğrenme modeli gösterilmiştir.



Şekil 3.4. Derin Öğrenme Modeli

3.3. Makine Öğrenmesi Algoritmaları ve Veri Çoğaltma Tekniği

3.3.1. Destek Vektör Makineleri (SVM)

Sınıflandırma ve regresyon analizinde kullanılan güçlü ve esnek bir algoritmadır. SVM, veriyi yüksek boyutlu bir uzaya dönüştürerek en iyi ayırım yapabilen hiper düzlemi bulur. Bu hiper düzlem, farklı sınıfları mümkün olan en geniş marj ile ayıran düzlemdir. SVM, doğrusal olmayan sınıflandırma problemlerinde de etkilidir; bu durumda, kernel fonksiyonları kullanarak veriyi daha yüksek boyutlu bir uzaya projekte eder. SVM, özellikle küçük ve orta büyüklükteki veri setlerinde yüksek performans gösterir. Ancak, büyük veri setlerinde hesaplama maliyeti yüksek olabilir. SVM, görüntü tanıma, biyomedikal veri analizi ve metin sınıflandırma gibi çeşitli uygulamalarda yaygın olarak kullanılır. Örneğin, el yazısı tanıma sistemlerinde SVM, oldukça başarılı sonuçlar elde etmiştir. SVM'nin esnekliği ve doğruluğu, onu birçok makine öğrenmesi görevinde tercih edilen bir yöntem haline getirmiştir [22].

3.3.2. K-En Yakın Komşu (KNN)

En basit makine öğrenmesi algoritmalarından biridir ve sınıflandırma ile regresyon problemlerinde kullanılır. KNN, bir veri noktasını sınıflandırmak için en yakın k komşusunun sınıfına bakar. Bu komşuların sınıfları, yeni veri noktasının sınıfını belirler. KNN, eğitim aşamasında veri saklar ve test aşamasında sınıflandırma

yapar, bu yüzden bellek yoğun ve hesaplama maliyeti yüksektir. Özellikle büyük veri setlerinde ve yüksek boyutlu verilerde performans düşebilir. Ancak, parametre ayarlaması ve veri ön işleme ile KNN performansı artırılabilir. KNN, sezgisel ve anlaşılması kolay bir algoritmadır. Ayrıca, doğrusal olmayan ilişkileri iyi yakalar. Görüntü tanıma, metin madenciliği ve öneri sistemleri gibi birçok alanda kullanılır. Örneğin, tavsiye sistemlerinde, kullanıcıların beğenilerine göre benzer ürünler önerir [23].

3.3.3. Karar Ağaçları

Veri setini özelliklere göre bölerek sınıflandırma veya regresyon yapar. Ağaç yapısı, karar verme sürecini görselleştirir ve yorumlanabilirliği artırır. Her düğüm, bir özellik üzerinde bir karar verir ve dallar bu karara göre ayrılır. Son yaprak düğümleri, sınıfları veya değerleri temsil eder. Karar ağaçları hem kategorik hem de sürekli verilerle çalışabilir. Ayrıca, ön işlem gerektirmez ve eksik verilerle başa çıkabilir. Ancak, karar ağaçları aşırı uyum (overfitting) sorununa yatkındır. Bu sorun, ağaç derinliği sınırlandırılarak veya budama teknikleri kullanılarak çözülebilir. Karar ağaçları, pazarlama stratejileri, kredi riski analizi ve tıbbi tanı sistemleri gibi alanlarda yaygın olarak kullanılır. Örneğin, bir bankanın kredi başvurularını onaylama sürecinde, karar ağaçları kullanılabilir [24].

3.3.4. Lojistik Regresyon

İki sınıf arasında ayırım yapmak için kullanılan bir istatistiksel modeldir. Lojistik fonksiyon kullanarak, bağımlı değişkenin olasılığını modellemeye çalışır. Bu fonksiyon, çıkışı 0 ile 1 arasında bir değer olarak verir. Lojistik regresyon, özellikle ikili sınıflandırma problemlerinde etkilidir. Model, verinin doğrusal bir kombinasyonunu kullanarak logit dönüşümünü gerçekleştirir ve ardından lojistik fonksiyon ile bu değeri olasılığa çevirir. Lojistik regresyon, eğitim verisi üzerinde en uygun ağırlıkları bulmak için maksimum olabilirlik tahmini kullanır. Bu algoritma, tıp, ekonomi ve sosyal bilimlerde yaygın olarak kullanılır. Örneğin, hastalık teşhisinde, bir hastanın belirli bir hastalığa sahip olma olasılığını belirlemek için kullanılır. Ayrıca, lojistik regresyon, pazarlama kampanyalarının başarısını tahmin etmek için de kullanılır [25].

3.3.5. Rastgele Orman

Birçok karar ağacının birlikte çalıştığı bir topluluk öğrenme yöntemidir. Her bir ağaç, veri setinin farklı bir alt kümesiyle eğitilir ve sonuçlar çoğunluk oylamasıyla belirlenir. Bu yöntem, tek bir ağacın aşırı uyum (overfitting) sorununu azaltır ve genel performansı artırır. Hem sınıflandırma hem de regresyon problemlerinde kullanılabilir. Model, genellikle daha yüksek doğruluk sağlar ve daha az parametrik ayarlama gerektirir. Ayrıca, modelin değişken önemini belirleyerek, hangi özelliklerin tahminlerde daha etkili olduğunu gösterebilir. Rastgele orman algoritması, büyük veri setlerinde ve yüksek boyutlu verilerde iyi performans gösterir. Finansal analizler, biyoinformatik ve pazarlama analitiği gibi alanlarda yaygın olarak kullanılır. Örneğin, müşteri segmentasyonu ve kredi riski değerlendirmesinde başarılı sonuçlar verir [26].

3.3.6. Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE)

Sınıflandırma problemlerinde dengesiz veri setleri ile başa çıkmak için kullanılan bir yeniden örnekleme yöntemidir. Bu teknik, azınlık sınıfındaki örnekleri artırarak veri setini dengelemeyi amaçlar. SMOTE, azınlık sınıfındaki mevcut örnekler arasında yeni örnekler oluşturur. Bu, K-en yakın komşu (KNN) algoritmasını kullanarak yapılır; her azınlık sınıfı örneği için k en yakın komşu bulunur ve bu komşular arasındaki doğrusal interpolasyon ile yeni örnekler üretilir. Bu sayede, azınlık sınıfı temsilini artırarak modelin genel performansını ve doğruluğunu iyileştirir. SMOTE, özellikle tıbbi teşhis, kredi riski analizi ve dolandırıcılık tespiti gibi dengesiz veri setlerinin yaygın olduğu alanlarda kullanılır. Model eğitimi sırasında, SMOTE'nin uygulanması, azınlık sınıfındaki örneklerin aşırı uyum sorununu azaltabilir. Ayrıca, bu teknik, veri kümesinin çeşitliliğini artırarak, sınıflandırma algoritmalarının daha genel bir model oluşturmasına yardımcı olur. SMOTE, sınıf dengesizliğinin olumsuz etkilerini hafifletmek için etkili bir yöntemdir ve birçok makine öğrenmesi uygulamasında başarılı bir şekilde uygulanmıştır [27].

3.4. Derin Öğrenme Mimarileri

Tez kapsamında Evrimsel Sinir Ağ (CNN) modelleri üzerine bir çalışma yapılmıştır. Bu bölümde sadece CNN mimarisinden bahsetmekle kalmayıp diğer derin öğrenme mimarilerinden de bahsedilmiştir.

3.4.1. Evrişimsel Sinir Ağları (CNN)

Evrişimsel Sinir Ağları (CNN), derin öğrenme algoritmalarından olup özellikle görüntü işlemede kullanılan bir mimaridir. CNN, girdi olarak alınan görüntüleri işlemek için oluşturulan katmanlardan oluşur. Bu katmanlar, görüntülerin özelliklerini çıkarmak ve sınıflandırmak için kullanılır [28].

CNN mimarisi genellikle aşağıdaki bileşenleri içerir:

Evrişim katmanı: Bu katman, filtreler aracılığıyla görüntü üzerinde farklı özellikleri tanımlar. Bu filtreler, görüntüdeki özellikleri tespit etmek için ağırlıklar kullanır.

Havuzlama katmanı: Bu katman, görüntü boyutunu küçültür ve önemli özellikleri korur.

Aktivasyon katmanı: Bu katman, aktivasyon fonksiyonları (ReLU, sigmoid vb.) kullanarak, sinir ağının çıktılarını belirler.

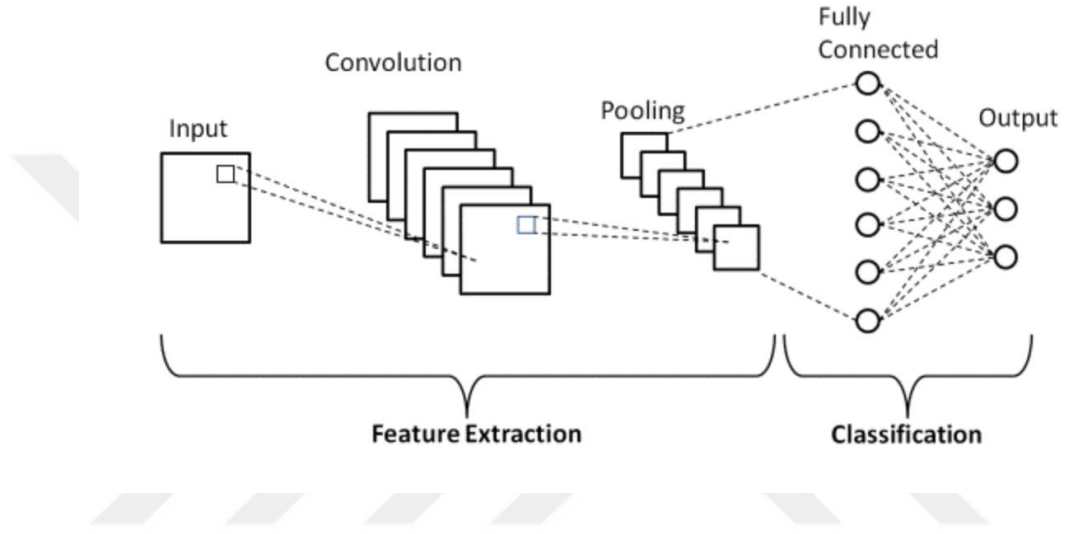
Tam Bağlantılı Katman: Bu katman, özellikleri sınıflandırmak için kullanılır. Bu katmanda, tüm özellikler birbirine bağlanır ve çıktılar, tahmin edilen sınıflara göre hesaplanır.

CNN mimarisi, özellikle görüntü sınıflandırma gibi işlemlerde, yüksek doğruluk oranları sağlayabilir. Bununla birlikte, doğru sonuçlar elde etmek için, genellikle büyük ve çeşitli veri kümeleri üzerinde eğitilmesi gerekir. Diğer sinir ağlarından farklı olarak, özellikle görüntü işleme verilerinde etkili bir şekilde kullanılan bir mimaridir. Bir CNN, birbirine bağlı birçok öğrenme katmanından oluşur. Her öğrenme katmanı, önceki katmanın çıkışını girdi olarak alır ve bir dizi filtre ile öznitelikleri tespit eder. Bu filtreler, ağırlıklardan oluşan matrislerdir ve öğrenme süreci boyunca optimize edilirler. Özellikle görüntü sınıflandırma, nesne tespiti, yüz tanıma, gibi alanlarda kullanılmaktadır.

Geleneksel görüntü sınıflandırma tekniklerinden farklı olarak, derin öğrenme yöntemleri özellik çıkarma veya ön işleme gerektirmez. Bunun yerine, derin öğrenme modelleri bu görevleri yardım almadan bağımsız olarak gerçekleştirir. Bu görevler için katmanlı bir yapıya sahip olan CNN kullanılmaktadır. Giriş katmanı, CNN'deki ilk katmandır, ardından görüntü özelliklerinin çıkarıldığı evrişim katmanı gelir ve

sınıflandırma katmanı son katmandır. Evrişim, havuzlama, aktivasyon, tam bağlantılı katmanlarının tümü ara katmanın parçalarıdır.


Şekil 3.5’de görüldüğü gibi CNN mimarileri üzerinde resim verilerimiz alınıp evrişim (Convolution) katmanı ardından havuzlama (Pooling) katmanları ile resmimize ait özellikler çıkarılır. Tam bağlantılı (Fully Connected) katmanı ile yapay sinir ağları üzerinden sınıflandırmalar gerçekleştirilir.



Şekil 3.5. CNN Mimarisi

3.4.2. Tekrarlayan Sinir Ağı (RNN)

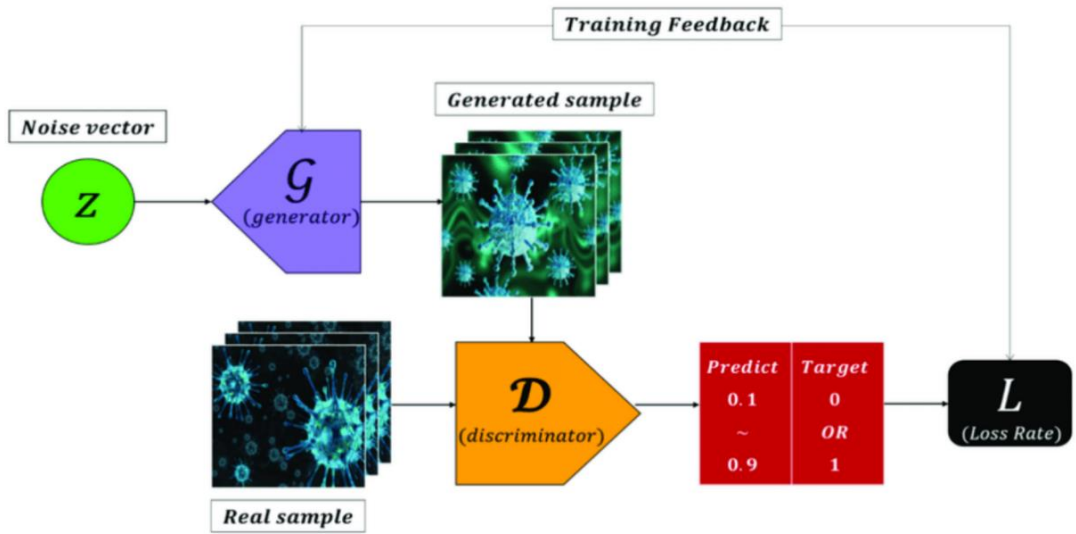
Bir girdi dizisi ile çalışan bir sinir ağıdır. Girdi verilerinin zaman serileri şeklinde organize edildiği durumlarda kullanılırlar. RNN’ler, bir önceki adımda hesaplanan çıktıları, bir sonraki adımda kullanarak, geçmiş bilgiyi korur ve bu nedenle özellikle metin, zaman serileri, ses işleme gibi doğal dil işleme uygulamalarında sıklıkla kullanılır [29]. Şekil 3.6’da RNN mimarisi gösterilmiştir.



Şekil 3.6. RNN Mimarisi

3.4.3. Çekişmeli Üretici Ağ (GAN)

Birbirine karşı yarışan iki sinir ağının bir araya getirilmesiyle oluşan bir yapay zeka türüdür. GAN'lar, özellikle görüntü oluşturma veya görüntüyü manipüle etme gibi görsel işleme uygulamalarında kullanılırlar. Bir GAN, iki ayrı ağdan oluşur: biri veri üretirken, diğeri bu verileri gerçek veya sahte olarak sınıflandırır. Bu iki ağ birbirleriyle yarışarak, sonunda gerçeğe çok benzeyen sahte veriler üretebilirler [30]. Şekil 3.7'de GAN mimarisi verilmiştir.



Şekil 3.7. GAN Mimarisi

Bu mimarilerin her biri, farklı problemler için özelleştirilmiştir ve verilerin yapısına göre seçilirler. Yapay zeka ve makine öğrenmesi alanında, her geçen gün yeni mimariler ve modeller geliştirilmekte ve var olan modeller geliştirilmekte veya değiştirilmektedir.

3.4.4. Uzun Kısa Süreli Bellek (LSTM)

LSTM, özellikle zaman serileri verileri, doğal dil işleme ve diğer sekans problemleriyle çalışırken kullanılmak üzere tasarlanmış bir tür yapay sinir ağıdır. LSTM'ler, uzun süreli bağımlılıkları öğrenme yeteneği ile bilinirler, bu da onları kısa süreli hafıza sorunlarına karşı daha dayanıklı kılar. LSTM, sekans verileriyle çalışırken klasik RNN'lerin karşılaştığı uzun süreli bağımlılık problemlerini çözmede büyük bir ilerleme sağlamıştır. Ancak, hesaplama açısından daha maliyetli olabilir ve bazı durumlarda daha yeni alternatifler (örneğin, Transformer modelleri) daha etkili olabilir. LSTM'in güçlü yönleri, özellikle uzun metinler veya uzun süreli bağımlılıkların önemli olduğu görevlerde, onu hala pek çok uygulama için değerli bir araç haline getirmektedir. LSTM, doğal dil işleme, zaman serisi tahmini ve ses tanıma problemlerinde sıklıkla kullanılmaktadır.

3.5. Derin Öğrenme Katmanları

3.5.1. Giriş (Input) Katmanı

Derin öğrenme modellerinde giriş (input) katmanı, modelin veri işlemeye başladığı ilk noktadır. Bu katman, modelinize girecek olan ham veriyi alır ve modelin diğer katmanlarına aktarılacak şekilde hazırlar. Giriş katmanının temel amacı, veriyi bir sonraki katmana aktarılacak uygun bir formata dönüştürmektir. Bu, genellikle verinin normalize edilmesi, ölçeklendirilmesi veya başka ön işlemlerle işlenmesi anlamına gelebilir.

Giriş Katmanının Özellikleri:

Veri Boyutu : Giriş katmanı, modelin alabileceği verinin boyutunu (örneğin, bir görüntüdeki piksellerin sayısı veya bir metin dökümanındaki kelimelerin sayısı gibi) belirler. Bu, modelin başa çıkabileceği veri türünü ve miktarını doğrudan etkiler.

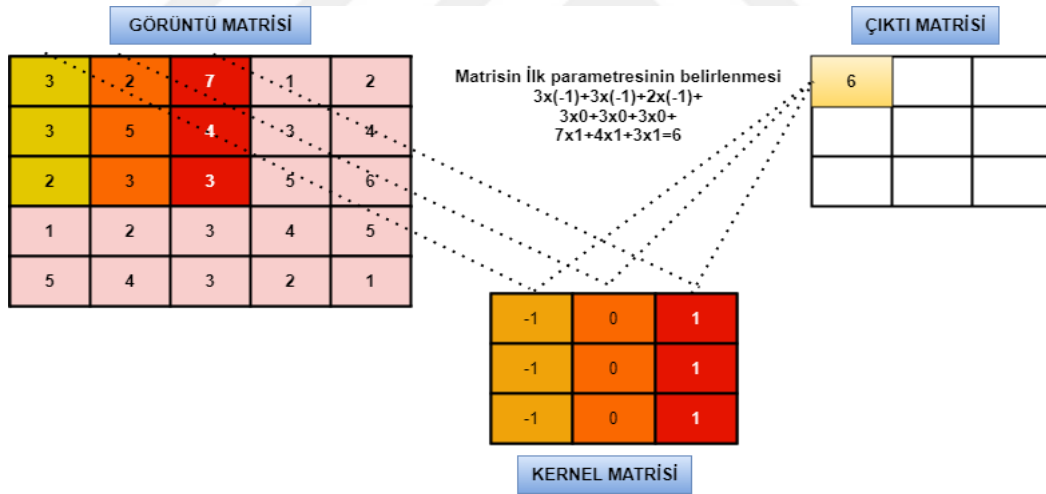
Ön İşlem: Giriş verisinin, model tarafından daha etkili bir şekilde işlenebilmesi için çeşitli ön işlemlerden geçirilmesi gerekebilir. Bu işlemler arasında normalizasyon, standardizasyon, eksik verilerin doldurulması veya veri artırma bulunabilir.

Veri Türü: Giriş katmanı, modelin işleyeceği veri türünü de tanımlar. Bu, sayısal veriler, kategorik veriler, görüntüler, ses sinyalleri, metinler gibi farklı türlerde olabilir.

Giriş katmanı, modelin geri kalanı için bir temel oluşturur ve modelin başarısında önemli bir rol oynar. İyi tasarlanmış bir giriş katmanı, modelin veriyi daha etkin bir şekilde öğrenmesine ve genel performansının artmasına yardımcı olabilir. Bu nedenle, giriş katmanının doğru şekilde yapılandırılması ve gerekli ön işlemlerin yapılması, derin öğrenme projelerinde kritik öneme sahiptir.

3.5.2. Evrişim Katmanı

Evrişim, sınır ağları kavramının ana tabanını oluşturan bölümdür. Bu bölümde daha önceden belirlenmiş bir filtrenin giriş verisini tarayarak girdinin bariz niteliklerini meydana çıkarmayı hedeflemektedir. Filtreleme son bulduğunda girdi verisinden daha küçük bir matris elde edilir [31].




Şekil 3.8. Evrişim İşlemi ile Çıktı Matrisi

Şekil 3.8’de evrişim işlemi görülmektedir. Derin öğrenme algoritmalarından farklı ölçeklerde filtreleme kullanılarak konvolüsyon işlemi uygulanır. AlexNet için 11x11 boyutunda matrisler bulunurken, ZfNet’te de 7x7 boyutunda filtreler uygulanmaktadır. Aynı şekilde diğer mimariler incelendiğinde GoogleNet, VggNet, ResNet ise 5x5, 3x3, 2x2, 1x1 boyutunda filtrelemeler uygulanmış ve NxN ölçeğindeki matrise MxM ölçeğinde matris kullanılmaktadır [32].

3.5.3. Aktivasyon (ReLU) Katmanı

Aktivasyon fonksiyonları, derin öğrenme modellerindeki nöronların çıktılarını dönüştürmek için kullanılır ve bu dönüşümler sayesinde, modeller doğrusal olmayan problemleri çözebilir. ReLU aktivasyon fonksiyonu, en popüler aktivasyon fonksiyonlarından biridir ve özellikle derin sinir ağlarında sıkça tercih edilir.

ReLU aktivasyon fonksiyonu, türev işlemini gerçekleştirebilen doğrusal olmayan bir aktivasyon fonksiyonudur. Derin öğrenme mimarilerinde fazla sayıda aktivasyon fonksiyonu olmasına rağmen, ReLU $f(x)=\max(0,x)$ fonksiyonu kullanılmaktadır [33].



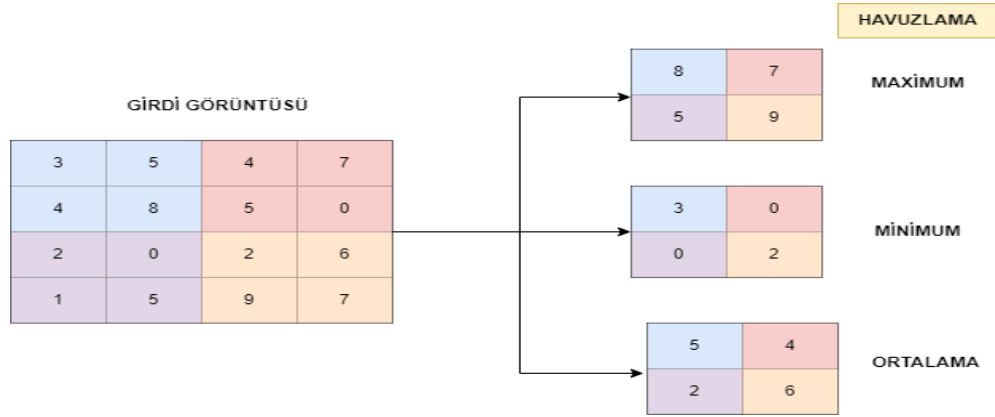
Şekil 3.9. ReLU İşlevi

Şekil 3.9'da görüleceği üzere ReLU işleminde çıkan sonuç eğer negatifse 0, pozitifse 1 çıktı sonucunu verir.

3.5.4. Havuzlama (Pooling) Katmanı

Havuzlama (Pooling) katmanları, genellikle evrimsel sinir ağları (CNN) içerisinde yer alan ve özellik haritalarının (feature maps) boyutunu azaltmak için kullanılan özel bir katman türüdür. Bu işlem, modelin hesaplama yükünü azaltırken

aynı zamanda özellik haritalarının aşırı uyum (overfitting) karşı direncini artırır. Havuzlama katmanları, özellikle görüntü işleme görevlerinde, modelin küçük dönüşümlere ve yer değiştirmelere karşı daha toleranslı olmasına yardımcı olur.



Şekil 3.10. Havuzlama İşlem Örneği

Havuzlama işleminin bir örneği Şekil 3.10'da verilmiştir. Bu katmanda uygun bir filtre yardımıyla hareket edilir. Kullanılan NxN boyutundaki filtre veri havuzu içinde dolaştırılıp matris içerisinde mevcut olan en elverişli değerlerin tespitine odaklanır. Değerlerin tespitinde en fazla kullanılan ortalama ve maksimum havuzlama işlemleridir. Maksimum değer havuzlama işleminde NxN boyutlu matris içindeki maksimum değer, meydana gelecek 1x1 boyutlu matrisin yeni değeridir [34].

Ortalama değer havuzlama işleminde ise NxN boyutlu matris içinde kalan tüm sayıların aritmetik ortalamasının sonucu, meydana gelecek 1x1 boyutlu matrisin yeni değerini vermektedir [32].


3.5.5. Tam Bağlı (Full-Connected) Katman

Tam bağlı (Fully Connected, FC) katmanlar, derin öğrenme modellerinde, özellikle de sinir ağlarında geniş çapta kullanılan bir katman türüdür. Bu katmanlar, gelen verinin her bir özelliğini ağın önceki katmanındaki her bir nörondan alınan bilgilerle birleştirerek, karmaşık ilişkileri ve örüntüleri öğrenmeyi amaçlar. Bir tam bağlı katman, modelin çıktı katmanına yakın yerlerde genellikle son işleme aşamasında bulunur ve özellikle sınıflandırma ve regresyon gibi görevler için son tahminlerin yapılmasında kritik bir role sahiptir. Şekil 3.11'de gösterilmiştir.

Kullanım Alanları ve Avantajları:

Sınıflandırma ve Regresyon: Tam bağlı katmanlar, çeşitli sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılır. Özellikle, bir sinir ağının son katmanı genellikle bir sınıflandırma görevi için softmax aktivasyon fonksiyonu içeren tam bağlı bir katmandır.

Özellik Entegrasyonu: Bu katmanlar, modelin önceki katmanlardan gelen özellikler arasındaki karmaşık ilişkileri öğrenmesine olanak tanır. Bu sayede, giriş verisi üzerinde yüksek seviyeli özellik entegrasyonu ve analizi gerçekleştirilebilir.




Şekil 3.11. Tam Bağlı Katman

3.5.6. Dropout katmanı

Dropout, derin öğrenme modellerinde aşırı uyumu (overfitting) önlemek için kullanılan etkili bir düzenleme (regularization) tekniğidir. Geoffrey Hinton ve ekibi tarafından geliştirilen bu yöntem, eğitim sırasında rastgele seçilen nöronların (ve bu nöronların bağlantılarının) geçici olarak "atıl" duruma getirilmesiyle çalışır. Bu işlem, her eğitim adımında ağın farklı bir "alt kümesini" eğitir, böylece modelin eğitim veri setine aşırı uyum sağlamasını engeller ve genelleştirme yeteneğini artırır.

Şekil 3.12'de çok katmanlı yapay sinir ağı ve dropout işlemi uygulanmış ağ yapısı gösterilmiştir. Bu işlem ile bazı düğümler ortadan kaldırılmış ve sağda bulunan şekilde de çarpı işaretiyle gösterilmiştir.



Şekil 3.12. (A) Çok Katmanlı Yapay Sinir Ağ Örneği (B) Dropout İşlemi Uygulanmış Sinir Ağ Örneği

3.5.7. Sınıflandırma (Classification) Katmanı

Sınıflandırma katmanı, genellikle bir derin öğrenme modelinin en son katmanıdır ve modelin çıktısını belirli sınıflara atamak için kullanılır. Bu katman, model tarafından öğrenilen özelliklerin ve temsillerin, belirli sınıflandırma görevlerine uygun sonuçlar üretmek üzere kullanılmasını sağlar. Özellikle, çok sınıflı sınıflandırma görevlerinde, çıktı katmanındaki her nöron bir sınıfı temsil eder ve her nöronun çıktısı, ilgili sınıfa ait olma olasılığını ifade eder. Sınıflandırma katmanı, modelin eğitim verilerinden öğrendiği bilgileri son kullanıcıya yararlı tahminler olarak sunma yeteneği açısından kritik bir öneme sahiptir. Bu katmanın doğru şekilde yapılandırılması ve uygun aktivasyon fonksiyonunun seçilmesi, modelin genel performansını ve doğruluğunu doğrudan etkiler.

3.5.8. Yumuşatma (Softmax) Katmanı

Yumuşatma (Softmax) katmanı, genellikle bir derin öğrenme modelinin çok sınıflı sınıflandırma görevlerinde kullanılan son katmandır. Bu katman, modelin çıktılarını, her bir sınıf için bir olasılık dağılımı üreten normalize edilmiş değerlere dönüştürür. Softmax katmanının temel amacı, modelin çıktılarını, tüm sınıfların olasılıklarının toplamının 1 olacağı şekilde ölçeklendirmek ve böylece her bir çıktının bir sınıfın tahmini olasılığını temsil etmesini sağlamaktır.

Softmax sınıflandırıcının avantajları, softmax algoritması kullanılarak lineer olarak ayrılabilen temel problemlerin verimli bir şekilde sınıflandırılmasını içerir ve basit model yapısı, eğitmeyi ve tahmin etmeyi kolaylaştırır. Bu sınıflandırıcının

dezavantajı, yalnızca doğrusal olarak ayrılabilir veriler üzerinde çalışması ve boş reddetmeyi desteklememesidir [35].

3.6. CNN Algoritmaları

3.6.1. DenseNet

Eldeki verilerin ve kaynakların daha verimli kullanımını hedefleyen ve derin öğrenme modellerinde sıklıkla kullanılan bir model olan DenseNet, 2016 yılında Huang vd tarafından önerilmiştir [36]. DenseNet, diğer CNN modellerinden farklı olarak, katmanlar arasında değil katmanlar içinde yoğun bir bağlantı kurar. Bu yoğun bağlantı sayesinde, her katmanın çıkışı, kendisinden önceki tüm katmanların çıkışlarını girdi olarak alır ve kendisinden sonraki tüm katmanlara doğrudan bağlanır. Bu sayede, her katmanın hem kendi girdisi hem de önceki katmanların girdileri ile çalışması sağlanır. Bu bağlantıların sayesinde ayrıca, gradientlerin daha iyi iletimi ve eğitim sürecinde daha az parametrenin kullanılması gibi avantajlar da elde edilir. DenseNet, "growth rate" olarak adlandırılan bir parametre ile kontrol edilen bir hiperparametre kullanır. Bu parametre, her katmanın kaç öğrenme filtresine sahip olacağını belirler. Ayrıca, modelde birkaç yoğun blok kullanılarak, daha derin ağların oluşturulmasına olanak tanır. DenseNet, özellikle sınırlı veri kaynaklarına sahip uygulamalarda başarılı sonuçlar verirken, aynı zamanda daha az parametre kullanarak daha yüksek doğruluk oranları elde edebilir. Bu özellikleri sayesinde, yoğun bir bağlantı ağına sahip modellerin eğitimi daha hızlı ve daha verimli hale gelir.

3.6.2. MobileNet

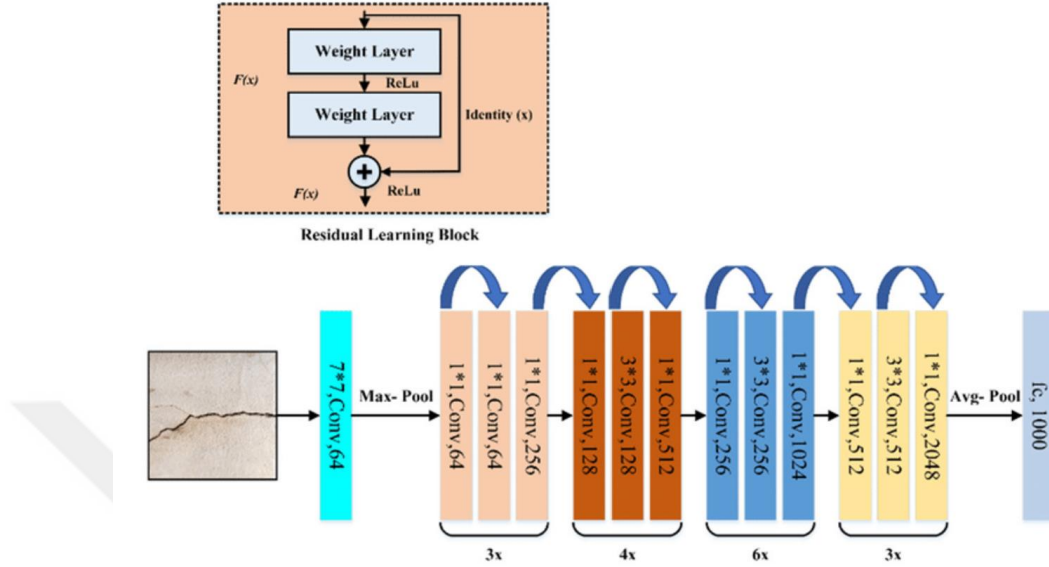
MobileNet, Google tarafından geliştirilen ve özellikle mobil ve gömülü cihazlarda verimli bir şekilde çalışmak üzere tasarlanmış bir derin öğrenme modelidir. Geleneksel derin sinir ağlarına kıyasla daha az hesaplama gücü ve enerji tüketimi gerektiren MobileNet, bu özellikleri sayesinde taşınabilir cihazlarda gerçek zamanlı uygulamalar için idealdir. MobileNet'in temel yapısı, derinliği ayrılmış evrişimler (depthwise separable convolutions) kullanarak hesaplama yükünü önemli ölçüde azaltır. Bu teknik, standart evrişim işlemini iki aşamaya böler: derinlik evrişimi (depthwise convolution) ve nokta evrişimi (pointwise convolution). Derinlik evrişimi, her bir giriş kanalına ayrı ayrı uygulanırken, nokta evrişimi, bu sonuçları birleştirerek çıktıyı oluşturur. MobileNet modeli, farklı hassasiyet ve performans gereksinimlerini karşılamak için genişlik çarpanı (width multiplier) ve çözünürlük çarpanı (resolution

multiplier) adı verilen iki hiperparametre içerir. Genişlik çarpanı, modelin genişliğini değiştirerek katmanlardaki filtre sayısını kontrol ederken, çözünürlük çarpanı, giriş görüntüsünün boyutunu ayarlar. Bu iki parametre, modelin hesaplama maliyetini ve doğruluğunu dengelemek için ayarlanabilir. MobileNet'in bir diğer önemli özelliği, esnekliği ve modüler yapısıdır. Bu yapı, çeşitli görevler için kolayca uyarlanabilen ve transfer öğrenme teknikleri ile önceden eğitilmiş modellerin yeniden kullanılmasına olanak tanır. MobileNet, görüntü sınıflandırma, nesne tespiti ve semantik segmentasyon gibi çeşitli bilgisayarla görme görevlerinde kullanılmaktadır [37].

3.6.3. ResNet

Derin öğrenme mimarilerinde kullanılan bir CNN modelidir. Bu model, özellikle derin yapılarda görülen geriye doğru yayılım sırasında kaybolan gradyan sorununu çözmek amacıyla geliştirilmiştir. ResNet'in temel fikri, önceki katmanların çıktılarının, daha sonra gelen katmanlardan birine doğrudan aktarılmasıdır. Bu katmanlar arasındaki doğrudan bağlantılar, önceki katmanların öğrenilen özelliklerinin korunmasına ve kullanılmasına olanak tanır. Bu sayede daha derin ağlar oluşturulabilir ve daha yüksek doğruluk elde edilebilir. ResNet mimarisi, blok adı verilen yapıların birleşimi ile oluşturulur. Bu bloklar, iki veya üç katmandan oluşur. İki katmanlı bloklara temel blok adı verilirken, üç katmanlı bloklara şişirilmiş blok adı verilir. Her blok, girdi verilerini aynı boyutta çıkış verilerine dönüştüren bir dizi katman içerir. ResNet ayrıca, ağın en üstünde yer alan global ortalama havuzlama katmanından sonra bir tam bağlı katman yerine, bir özellik çıkarımı yapmak için bir havuzlama katmanı ve ardından bir softmax çıktı katmanı ile sona erer. ResNet, ImageNet veri kümesinde ve diğer birçok görevde başarılı sonuçlar vermiştir ve günümüzde en popüler ESA modellerinden biridir. ResNet'in blok adı verilen yapıları, her blokta birden fazla küçük katmanın ardışık olarak kullanılması yerine, birkaç katmanın doğrudan atlanarak sonraki bloğa aktarılması yoluyla oluşur. Bu sayede, ağın daha derin hale getirilmesi mümkün hale gelirken, aynı zamanda daha az parametre kullanarak daha iyi sonuçlar elde edilebilir. Ayrıca, ResNet'in farklı boyutlarda filtreler kullanması, ağın farklı özellikleri öğrenmesine olanak tanır ve daha geniş bir veri yelpazesine uygulanabilir. ResNet, aralarında 34, 50, 101, 152 ve 1202 olmak üzere çeşitli katman sayılarına sahip çeşitli mimariler geliştirmiştir. Bunların en bilineni olan ResNet50, ağın sonunda bir tam bağlantılı katmana ve 49 konvolüsyon katmanına sahiptir. Giriş katmanına 224x224 boyutunda bir görüntü


beslenir. ResNet50 96 MB'dir ve 50 ana katman ve 25.6 milyon eğitilebilir parametre dahil olmak üzere toplam 177 katmana sahiptir [38,39]. Şekil 3.13'de ResNet50 modeli gösterilmiştir.



Şekil 3.13. ResNet50 Modeli

3.6.4. EfficientNet

EfficientNet, daha önceki modellere göre daha az parametre kullanarak yüksek doğruluk elde eden ve çeşitli boyutlarda kullanılacak bir CNN modelidir. ImageNet veri tabanından 14 milyondan fazla görüntü kullanılarak eğitildi. EfficientNet modeli, diğer gelişmiş modellerin aksine, daha etkili sonuçlar elde etmek için derinliği, genişliği ve çözünürlüğü ölçeklendirirken modelin boyutunu küçültmeyi amaçlar. EfficientNet grubu, karmaşıklığı B0 ile B7 arasında değişen sekiz modelden oluşur. Model sayısı arttıkça, hesaplanan parametrelerin sayısı nispeten sabit kalırken, doğruluk belirgin şekilde artar [40,41]. Şekil 3.14'de EfficientNetB0 modeli gösterilmiştir.



Şekil 3.14. EfficientNetBO Modeli

3.6.5. Inception

Inception, Google tarafından geliştirilen ve görüntü tanıma ve sınıflandırma gibi bilgisayarla görme görevlerinde yüksek performans gösteren bir derin öğrenme modelidir. İlk olarak 2014 yılında tanıtılan Inception, özellikle derin sinir ağlarının daha geniş ve daha derin yapılar kullanarak doğruluğunu artırmayı amaçlar. Inception mimarisinin temel amacı, bilgi kaybını minimize ederek ve hesaplama maliyetini dengeleyerek daha iyi performans elde etmektir. Inception modelinin en önemli bileşeni, aynı anda birden fazla boyutta filtre uygulayan ve farklı çözünürlüklerde bilgi çıkartan "Inception module" adlı modüldür. Bu modül, çeşitli boyutlardaki (örneğin, 1x1, 3x3 ve 5x5) evrişim filtrelerini aynı giriş verisi üzerinde paralel olarak çalıştırır ve ardından bu filtrelerin çıktısını birleştirir. Bu sayede, farklı ölçeklerdeki özellikler aynı anda öğrenilir ve modelin karmaşık yapıları tanıma yeteneği artar. Inception modeli, ImageNet yarışmasında yüksek başarı elde etmiş ve geniş çapta benimsenmiştir. Özellikle, Inception-v1 (GoogLeNet) mimarisi, 2014 ImageNet Large Scale Visual Recognition Challenge (ILSVRC) yarışmasında en iyi performansı göstererek dikkat çekmiştir. InceptionV3 ve InceptionV4 gibi daha gelişmiş sürümleri, doğruluk oranını daha da artırmış ve daha karmaşık görevlerde üstün performans sergilemiştir [42].

3.7. Derin Öğrenme Kütüphaneleri

Bu bölümde derin öğrenme mimarilerinde kullanılan kütüphaneler hakkında yapılan arařtırmalar sunulmuřtur.

3.7.1. TensorFlow

TensorFlow, Google tarafından geliřtirilen ve açık kaynak olarak sunulan popüler bir derin öğrenme ve makine öğrenimi kütüphanesidir. Yüksek performanslı sayısal hesaplamalar için tasarlanmıřtır ve hem arařtırma hem de üretim amaçlarıyla geniş çapta kullanılmaktadır. TensorFlow, veri akıř grafiklerini kullanarak karmařık hesaplamaları temsil eder, bu da kullanıcıların karmařık çok katmanlı derin öğrenme modellerini kolayca oluřturup eđitmelerine olanak tanır.

TensorFlow kullanılarak yapılan bir hesaplama, telefonlar ve tabletler gibi mobil cihazlardan yüzlerce makineden oluřan büyük ölçekli dađıtık sistemlere ve grafik iřleme birim (GPU) kartları gibi binlerce hesaplama cihazına kadar çok çeřitli heterojen sistemlerde çok az deđiřlikle veya hiç deđiřlik olmadan yürütülebilir. TensorFlow, konuřma tanıma, görüntü tanıma, robotik, bilgi alma ve dođal dil iřleme gibi makine öğrenimi sistemlerinin çođu alanında bir platform görevi görür [43].

3.7.2. Caffe, Caffe2

Caffe ve onun devamı niteliğindeki Caffe2, derin öğrenme modellerini geliřtirmek ve eđitmek için kullanılan açık kaynaklı kütüphanelerdir. UC Berkeley'nin BVLC (Berkeley Vision and Learning Center) tarafından geliřtirilen Caffe, özellikle görüntü iřleme ve sınıflandırma görevlerinde yüksek performans ve hız sunmasıyla tanınır. Caffe, BSD lisanslı C++ ile geliřtirilmiř bir çerçevedir ve Python ve MATLAB arayüzlerini kullanır. Caffe'nin CNN mimarisiyle iyi çalıřması, ileri beslemeli ađlar iyi performans sađlaması ve tam kod yazmadan eđitim modellerinin ince ayarına izin vermesi gibi bazı avantajları olmasına rađmen, zayıf dokümantasyona sahiptir. RNN mimarisi gibi büyük sinir ađlarında kötü ve hacimli performansı bu durumu kanıtlamaktadır [44].

3.7.3. Theano

Theano, derin öğrenme ve genel amaçlı matematiksel hesaplamalar için kullanılan bir Python kütüphanesidir. Montreal Üniversitesi'nde Mila - Quebec Yapay Zeka Enstitüsü tarafından geliřtirilmiř olan Theano, özellikle makine öğrenimi

arařtırmacıları arasında popöler olmuřtur. Theano'nun temel amacı, karmařık matematiksel ifadeleri tanımlamak ve bu ifadeler üzerinde verimli bir řekilde iřlem yapabilmek için bir araç saęlamaktır [45].

3.7.4. Torch

Torch, bilimsel hesaplamalar için kapsamlı bir kütüphane seti sunan, Lua programlama dili üzerine kurulu bir makine öęrenimi kütüphanesidir. Özellikle derin öęrenme, bilgisayarlı görü ve doęal dil iřleme gibi alanlarda yaygın olarak kullanılmaktadır. Torch'un temel özellięi, etkili bir řekilde GPU kullanımını desteklemesi ve yüksek performanslı sayısal hesaplama yetenekleridir. Bu özellikler, Torch'u büyük veri setleri üzerinde karmařık derin öęrenme modellerini eęitmek için uygun bir araç haline getirir. Torch, akademik arařtırmacılar ve endüstri profesyonelleri tarafından geniş bir yelpazede kullanılmaktadır. Ana kullanım alanları arasında görüntü ve ses iřleme, robotik, doęal dil iřleme ve dięer pek çok makine öęrenimi uygulaması bulunmaktadır [46].

3.8. Derin Öęrenme Uygulamaları

Bir önceki bařlıklarda derin öęrenme mimarileri ve kütüphaneleri üzerinden bir incelemeler özetlenmiřtir. Bu bölümde ise görüntü video iřleme alanlarında kullanılan yöntemler incelenecektir.

3.8.1. Görüntü/Video iřleme

Video görüntü iřlemenin temeli, bir görüntünün yoğunluk deęiřkenlięinin iki boyutlu bir dizi resim öęesi veya piksel olarak nicelemesidir. Siyah beyaz kameralardan gelen gri gölgeli resimler, bir renk bandından veya bantların birleřiminden tam renkli veya yoğunluk ve hatta kızılötesi gibi görsel olmayan bant verileri dahil olmak üzere çeřitli görüntü türleri kullanılabilir. Optimum temel sinyal, ilgilenilen sürece baęlıdır. Yoęunluk verilerinden bazı jeofiziksel ölçüler çıkarılır, örneęin bir dalganın sahil yüzündeki yükseliři veya batık bir kum çubuęu üzerinde kırılan bir dalganın konumu gibi videonun kullanılması, bu ölçümler için zamana baęımlılıęın karakterize edilmesini saęlar. Bu nedenle, herhangi bir çalıřma için video görüntü iřlemenin başarılı kullanımı, üç bileřenli problemin anlaşılmasını gerektirir. Artan zorluk sırasına göre bunlar:

- 1) Video örneklemenin zamansal yönleri,

2) Uzamsal yönler ve görüntü ile gerçek dünya koordinatları arasındaki dönüşümü,

3) Görüntü verileri ile ilgilenilen jeofiziksel sinyaller arasındaki ilişki [47].

Geleneksel bilgisayarlı görme ve makine öğrenimi yöntemleri, elle yazılmış rakamların veya trafik işaretlerinin tanınması gibi görevlerde insan performansı ile eşleşemez. Fakat geniş ve derin yapay sinir ağı mimarileri ile bu durum mümkün olabilmektedir.

Bu alanda yapılan çalışmalara bakıldığında; MNIST el yazısı karşılaştırmasında, kullanılan CNN mimarisi insana yakın performansa ulaşan ilk yöntemlerden olma özelliği taşımasının yanı sıra trafik işareti tanıma karşılaştırmasında, insanlardan iki kat daha iyi performans gösterir. Ayrıca, çok sayıda yaygın görüntü sınıflandırma kıyaslamasında en son teknolojiyi geliştirilen yöntemde; MNIST, NIST SD 19, çince karakterler, trafik işaretleri, CIFAR10 ve NORB üzerindeki tanıma oranlarını büyük ölçüde iyileştirmiştir [48].

3.8.1.1. Biyomedikal sinyal/görüntü işleme

Biyomedikal sinyal ve görüntü işleme, tıbbi verilerin daha iyi anlaşılması ve analiz edilmesi için kritik teknolojiler arasında yer alır. Bu alan, özellikle MRG, Bilgisayarlı Tomografi (CT) taramaları gibi görüntüleme tekniklerinin yanı sıra Elektrokardiyogram (EKG) ve Elektroensefalografi (EEG) gibi sinyal işleme uygulamaları için gelişmiş algoritmalar geliştirmeye odaklanmıştır. Son teknoloji yazılımlar ve yapay zeka modelleri, bu tür biyomedikal verilerin işlenmesinde büyük rol oynayarak, hastalıkların teşhis ve tedavisinde devrim yaratma potansiyeline sahiptir.

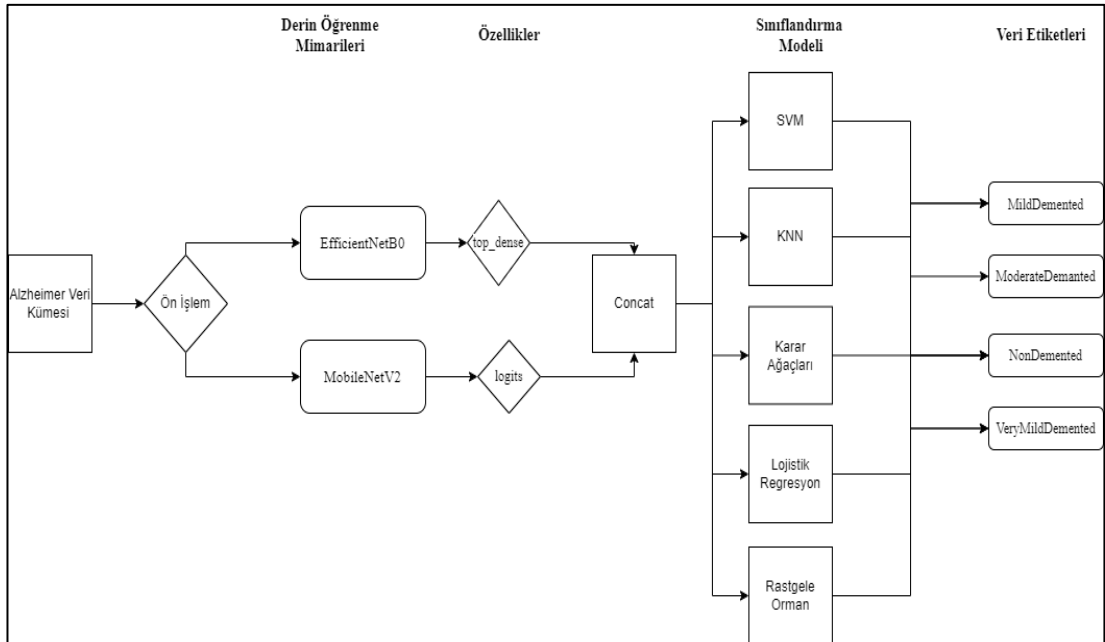
Sağlık alandaki derin öğrenme çalışmaları tüm hızıyla devam etmekte görüntünün olduğu her alanda güzel çalışmalar çıkarılmaktadır. Mesela, beyin tümörü ile ilgili yapılan çalışmalarda, görüntü segmentasyonuna ihtiyaç duyulmaktadır. Fakat son yıllarda görüntü işleme teknikleriyle de başarılı bir şekilde otomatik segmentasyon yapılmaktadır. Büyük miktarda MRG verileri, derin öğrenme modelleri sayesinde nesnel yorumların önünü açmıştır [49].

Bir çalışmada kullanılan yöntem tek bir ölçekte yalnızca 2B özellikleri kullanmasına rağmen, 3B çok ölçekli özellikleri kullanan son teknoloji bir yöntemden daha iyi performans göstermiştir [50]. Yapılan başka bir çalışmada, Kesme Dalga

Elastografisinden (SWE) alınan veriden öğrenilen görüntü özelliklerinin otomatik olarak çıkarılması için bir derin öğrenme mimarisi oluşturmayı ve iyi huylu ve kötü huylu meme tümörleri arasındaki ayırma derin öğrenme mimarisini değerlendirmeyi amaçlanmıştır. Derin öğrenme tabanlı yöntem, özellik öğrenmeyi SWE'de özellik seçimiyle bütünleştirir. Sonuçlandırılmasında ise meme kanserinin klinik bilgisayar destekli teşhisinde potansiyel olarak kullanılabilir önerisinde bulunulmuştur [51].

3.9. Önerilen Derin Öğrenme Tabanlı Hibrit Yöntem

Bu bölümde önerilen yaklaşımın ana temasını kısaca açıklayıp akış diyagramını, veri kümesi ve deneysel sonuçların değerlendirme metrikleri hakkında bilgiler paylaşılmıştır. İlk olarak veri kümesi, EfficientNetB0, ResNet50, DenseNet201, MobileNetV2 ve InceptionV3 mimarileri ile eğitilmiştir. Bu 5 mimari üzerinde temel sonuçlar alınmıştır, SMOTE ile veriler çoğaltılarak temel sonuçlar alınmıştır. SMOTE ile çoğaltılan veriler üzerinden mimarilerin son katmanlarından 1000 adet özellik ele alınıp SVM, KNN, Karar Ağaçları, Lojistik Regresyon ve Rastgele Orman algoritması ile sonuçlar alınmış olup, en yüksek sonuca sahip 2 model üzerinden hibrit bir model kurulmuştur. Önerilen hibrit modelin iş akış diyagramı Şekil 3.15’de verilmiştir.



Şekil 3.15. Önerilen Modelin İş Akış Diyagramı

3.9.1. Veri Kümesinin Tespiti ve Oluşum Aşamaları

Çalışmada ihtiyaç duyulan veri kümesi, kullanıcıların veri kümelerini bulmasına ve yayınlamasına olanak tanıyan çevrimiçi platform olan Kaggle'dan alınmıştır [52]. Veri kümesi, toplamda 6400 adet (224*224) piksel boyutlarından oluşan alzheimer'ın evrelerini temsil eden 4 farklı kategorik olarak sınıflandırılmış beyin MRG görüntülerinden oluşmaktadır [53]. Kategori açıklamaları:

Mild Demented: Hafif demans belirtileri gösteren bireylerin MRG görüntüleri.

Moderate Demented: Orta düzeyde demans belirtileri gösteren bireylerin MRG görüntüleri.

Non Demented: Demans belirtisi göstermeyen (sağlıklı) bireylerin MRG görüntüleri.

Very Mild Demented: Çok hafif demans belirtileri gösteren bireylerin MRG görüntüleri.

Verilerin dengesiz dağılması sebebiyle Sentetik Azınlık Örnekleme Tekniği (SMOTE) tekniği kullanılmıştır. SMOTE, sınıf dengesizliğini gidermek amacıyla azınlık sınıfına ait örnekleri artırarak yeni sentetik örnekler oluşturma tekniğidir. Bu yöntem, azınlık sınıfın temsil gücünü artırarak modelin öğrenme performansını iyileştirmektedir.

3.9.2. Sonuçların Toplanması ve Değerlendirme Aşaması

Tez çalışmasının gerçekleştirilmesinde programlama dili olarak python kullanılıp, derin öğrenme ve makine öğrenmesi algoritmaları için TensorFlow ve scikit-learn kullanılmıştır. Ayrıca bu çalışmanın testi için Google Colab platformu üzerinde 50 GB RAM ve 15 GB GPU özellikli donanım kullanılmıştır.

Performans değerlendirilmesi sırasında kullanılan karışıklık matrisi (confusion matrix) hesaplamaları için bazı parametreler kullanılmıştır. Kullanılan parametrelerin tanımları ve formülleri Çizelge 3.1'de açıklanmıştır.

Çizelge 3.1. Karışıklık Matrisinin Analizinde Kullanılan Metrikler

Metrik	Tanım	Formül
Kesinlik	Doğru pozitif tahminlerin, toplam pozitif tahminlere oranıdır.	$TP / (TP + FP)$
Duyarlılık	Doğru pozitif tahminlerin, toplam gerçek pozitiflere oranıdır.	$TP / (TP + FN)$
F1-Skoru	Kesinlik ve Duyarlılığın harmonik ortalamasıdır.	$2 * (Kesinlik * Duyarlılık) / (Kesinlik + Duyarlılık)$
Doğruluk	Tüm doğru tahminlerin, toplam tahminlere oranıdır.	$(TP + TN) / (TP + TN + FP + FN)$


4. ARAŞTIRMA BULGULARI

4.1. Veri Kümesinin Derin Öğrenme Mimarileriyle Başarımı ve Sonuçları

Önerilen yöntem, python programlama dili kullanılarak geliştirilmiştir. Çalışmamız üzerinde kullandığımız veri kümesi toplamda 6400 adet (224*224) piksel boyutlarından oluşan 4 farklı kategorik olarak sınıflandırılmış beyin MRG görüntülerinden oluşmaktadır. InceptionV3 modeli, giriş boyutu olarak (299*299) boyutlarında veri alması sebebiyle InceptionV3 modelinde (299*299) boyutlarında veri kullanılmıştır. Temel veri etiket dağılımları Çizelge 4.1’de, örnek veriler Şekil 4.1’de gösterilmiştir.

Çizelge 4.1. Temel Veri Etiket Dağılımları

Numara	Etiket	Sayı
0	MildDemented	896
1	ModerateDemented	64
2	NonDemented	3200
3	VeryMildDemented	2240



Şekil 4.1. Örnek Veriler

Verilerimiz üzerinde %70 eğitim %30 test olarak kullanılmıştır. 5 model üzerinden temel parametreler ile çıkarılan sonuçlar Çizelge 4.2’de gösterilmiştir.

Çizelge 4.2. Temel Model Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%58	%53	%53	%58
ResNet50	%58	%54	%55	%58
DenseNet201	%60	%58	%58	%60
MobileNetV2	%58	%53	%53	%58
InceptionV3	%56	%55	%55	%56

Verilerimiz üzerinde en yüksek doğruluk oranı %60 olduğu görülmüştür. Veriler üzerinde özellikle Moderate Demented sınıfında çok az veri olması sebebiyle, SMOTE tekniği ile veri çoğaltma işlemi yapılmıştır. Çoğaltılan verilerin etiket dağılımları Çizelge 4.3’te gösterilmiştir.

Çizelge 4.3. SMOTE Veri Etiket Dağılımları

Numara	Etiket	Sayı
0	MildDemented	3200
1	ModerateDemented	3200
2	NonDemented	3200
3	VeryMildDemented	3200

SMOTE ile çoğaltılan veriler üzerinden 5 model kullanılarak temel parametreler ile çıkarılan sonuçlar Çizelge 4.4’de gösterilmiştir.

Çizelge 4.4. SMOTE Temel Model Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%69	%67	%67	%69
ResNet50	%70	%70	%70	%70
DenseNet201	%72	%71	%72	%72
MobileNetV2	%61	%60	%60	%61
InceptionV3	%59	%59	%68	%59

SMOTE ile çoğaltılan veriler üzerinde doğruluk oranlarının daha yüksek olduğu görülmüştür. SMOTE ile çoğaltılan veriler üzerinden kullanılan 5 modelin son katmanlarından alınan 1000 adet özellik SVM, KNN, karar ağaçları, lojistik regresyon ve rastgele orman algoritmaları ile sınıflandırılmıştır.

SVM algoritması ile sınıflandırma sonuçları Çizelge 4.5’de gösterilmiştir.

Çizelge 4.5. SVM Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%89	%89	%89	%89
ResNet50	%73	%73	%74	%73
DenseNet201	%60	%58	%59	%60
MobileNetV2	%82	%82	%82	%82
InceptionV3	%26	%12	%28	%26

SVM algoritması ile en yüksek sonucu EfficientNetB0 ve MobileNetV2 modelleri vermiştir.

KNN algoritması ile sınıflandırma sonuçları Çizelge 4.6’da gösterilmiştir.

Çizelge 4.6. KNN Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%88	%88	%88	%88
ResNet50	%78	%77	%77	%78
DenseNet201	%76	%75	%76	%76
MobileNetV2	%78	%77	%78	%78
InceptionV3	%25	%12	%42	%25

KNN algoritması ile en yüksek sonucu EfficientNetB0, MobileNetV2 ve ResNet50 modelleri vermiştir.

Karar ağaçları algoritması ile sınıflandırma sonuçları Çizelge 4.7’de gösterilmiştir.

Çizelge 4.7. Karar Ağaçları Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%71	%71	%71	%71
ResNet50	%47	%47	%50	%47
DenseNet201	%35	%32	%42	%35
MobileNetV2	%58	%58	%58	%58
InceptionV3	%25	%10	%31	%25

Karar ağaçları algoritması ile en yüksek sonucu EfficientNetB0 ve MobileNetV2 modelleri vermiştir.

Lojistik regresyon algoritması ile sınıflandırma sonuçları Çizelge 4.8’de gösterilmiştir.

Çizelge 4.8. Lojistik Regresyon Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%85	%85	%85	%85
ResNet50	%77	%76	%77	%77
DenseNet201	%70	%69	%72	%70
MobileNetV2	%76	%76	%76	%76
InceptionV3	%27	%15	%42	%27

Lojistik Regresyon algoritması ile en yüksek sonucu EfficientNetB0, MobileNetV2 ve ResNet50 modelleri vermiştir.

Rastgele orman algoritması ile sınıflandırma sonuçları Çizelge 4.9’da gösterilmiştir.

Çizelge 4.9. Rastgele Orman Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
EfficientNetB0	%87	%87	%87	%87
ResNet50	%76	%76	%76	%76
DenseNet201	%35	%33	%52	%35
MobileNetV2	%75	%75	%75	%75
InceptionV3	%25	%10	%6	%25

Rastgele Orman algoritması ile en yüksek sonucu EfficientNetB0, MobileNetV2 ve ResNet50 modelleri vermiştir.

Makine öğrenme algoritmaları üzerinden sınıflandırmalarını incelediğimizde en başarılı 2 modelimiz EfficientNetB0 ve MobileNetV2 olmakla birlikte en kötü modelimiz InceptionV3 olmuştur.

4.1.1. Hibrit Model Oluşturulması ve Başarımı

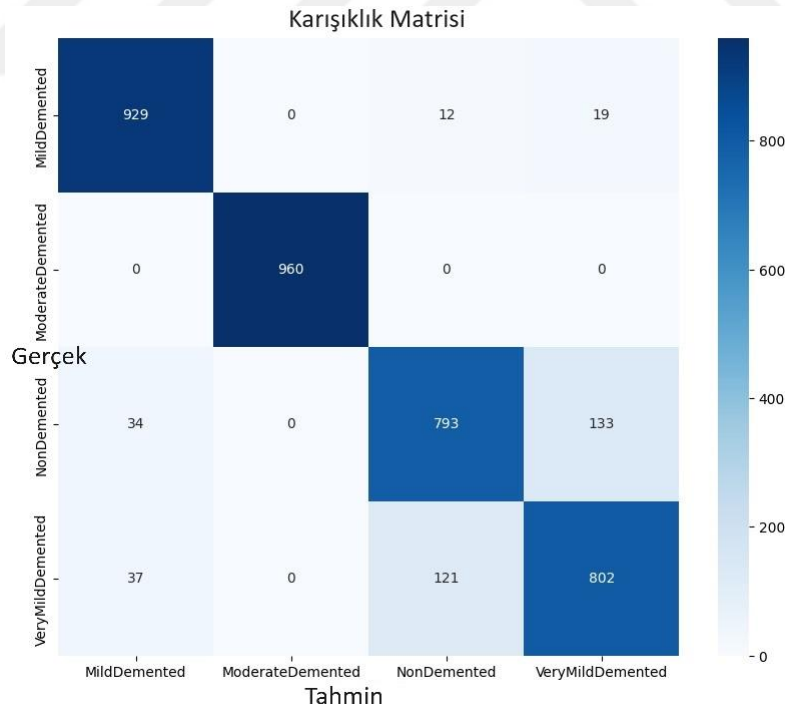
SMOTE ile çoğaltılmış veriler üzerinden en başarılı 2 modelimiz üzerinden hibrit bir model kurulmuştur. Bu hibrit modelimizin SVM, KNN, karar ağaçları,

lojistik regresyon ve rastgele orman algoritmaları ile sınıflandırma sonuçları Çizelge 4.10'da gösterilmiştir.

Çizelge 4.10. Hibrit Model Sonuçları

Model	Doğruluk	F1-Skoru	Kesinlik	Duyarlılık
SVM	%90	%90	%90	%90
KNN	%88	%88	%89	%88
Karar Ağaçları	%67	%66	%66	%67
Lojistik Regresyon	%86	%86	%86	%86
Rastgele Orman	%85	%85	%85	%85

Hibrit modelimiz ile SVM makine öğrenmesi algoritmasında %90 doğruluk oranıyla en başarılı model olmuştur. Hibrit modelimizin SVM algoritması kullanılarak test verisi üzerinde karışıklık matrisi Şekil 4.3'de gösterilmiştir.



Şekil 4.2. Hibrit SVM Karışıklık Matrisi

4.2. Tartışma

Derin öğrenme modellerinin veri kümesi üzerindeki performansını kapsamlı bir şekilde incelemektedir. Beyin MRG görüntülerinden oluşan veri kümesi, dört farklı kategoride sınıflandırılmıştır: MildDemented, ModerateDemented, NonDemented ve VeryMildDemented. Verilerin %70'i eğitim, %30'u test amacıyla kullanılmış ve beş farklı derin öğrenme modeli üzerinde değerlendirilmiştir. Temel model sonuçlarına göre, DenseNet201 modeli %60 doğruluk oranı ile en yüksek performansı sergilerken, diğer modellerin doğruluk oranları %56 ile %60 arasında değişmektedir.

Veri çoğaltma tekniği olarak kullanılan SMOTE, özellikle veri dengesizliğini gidermede etkili olmuştur. ModerateDemented sınıfında yeterli veri bulunmadığından, SMOTE ile veri çoğaltılarak tüm sınıflarda eşit veri dağılımı sağlanmıştır. Bu çoğaltılmış veriler üzerinde yeniden eğitilen modellerin sonuçlarına göre, DenseNet201 modeli %72 doğruluk oranı ile en yüksek performansı göstermiştir. Ayrıca, çoğaltılmış veriler üzerinde çeşitli makine öğrenmesi algoritmaları ile sınıflandırma yapılmış ve EfficientNetB0 mimarisi SVM algoritması ile %89 doğruluk oranına ulaşarak en başarılı sonuçları vermiştir. EfficientNetB0 ve MobileNetV2 ile oluşturulan hibrit model %90 doğruluk oranıyla en başarılı model olmuştur. Bu bulgular, SMOTE ile veri çoğaltmanın model performansını önemli ölçüde artırdığını ve farklı modellerle birlikte makine öğrenmesi algoritmalarının etkinliğini ortaya koymaktadır.

5. SONUÇ VE ÖNERİLER

Tez çalışması, Alzheimer hastalığının tespiti ve sınıflandırılmasında derin öğrenme mimarilerinin etkinliğini araştırmıştır. Çalışma kapsamında EfficientNetB0, ResNet50, DenseNet201, MobileNetV2 ve InceptionV3 gibi çeşitli derin öğrenme modelleri kullanılarak Alzheimer hastalığını tespit etmek üzere modeller geliştirilmiştir. Bu modellerin her biri, geniş veri kümeleri üzerinde eğitilerek Alzheimer hastalığının belirtileri taşıyan görüntülerle test edilmiştir. Araştırma sonuçları, bu modellerin yüksek doğruluk oranlarıyla hastalığı tespit edebildiğini göstermiştir.

Geliştirilen modeller arasında, özellikle hibrit model dikkat çekici sonuçlar sunmuştur. Hibrit model, farklı mimarilerin özelliklerini birleştirerek daha güçlü ve kapsamlı bir sınıflandırma performansı sergilemiştir. Bu model, tekil modellerin sahip olduğu sınırlamaları aşarak, daha karmaşık veri yapılarını ve ilişkilerini işleyebilmiş ve sonuç olarak Alzheimer hastalığının varlığını daha doğru bir şekilde tespit etmiştir. EfficientNetB0 ve MobileNetV2 ile oluşturulan hibrit model %90 doğruluk oranıyla en başarılı model olmuştur. Hibrit modelin başarısı, derin öğrenme tekniklerinin sağlık alanında, özellikle de nörodejeneratif hastalıkların erken teşhisinde nasıl bir potansiyele sahip olduğunu göstermektedir.

Bu araştırma, derin öğrenme mimarilerinin sağlık verileri üzerinde nasıl uygulanabileceği konusunda önemli içgörüler sunmaktadır. Alzheimer hastalığı gibi karmaşık ve çok boyutlu medikal görüntü verilerinin işlenmesinde derin öğrenme mimarileri, geleneksel görüntü işleme tekniklerine göre daha üstün sonuçlar sağlamaktadır. Bu, özellikle erken evre Alzheimer hastalığının tespit edilmesinde kritik bir avantaj sunmaktadır. Erken teşhis, hastalığın ilerlemesini yavaşlatma ve hasta bakım stratejilerini optimize etme imkanı tanımaktadır.

Araştırmanın ileriye dönük önerileri arasında, farklı derin öğrenme mimarilerinin ve hibrit modellerin daha geniş veri kümeleri üzerinde test edilmesi yer almaktadır. Alzheimer hastalığının farklı evrelerine ve türlerine özgü veri kümeleri üzerinde yapılan testler, modellerin genelleştirme kabiliyetini artırabilir ve diğer nörodejeneratif hastalıkların tespitinde de kullanılabilirliğini gösterebilir. Ayrıca, modelin farklı etnik kökenlerden ve coğrafyalardan gelen verilerle eğitilmesi, algoritmaların evrensel olarak uygulanabilirliğini test etme şansı verecektir.

Sonuç olarak, bu tez çalışması, Alzheimer hastalığının tespiti için derin öğrenme mimarilerinin potansiyelini ortaya koymaktadır. Araştırma sonuçları, hibrit modellerin ve özellikle derin öğrenme tekniklerinin, medikal görüntü işleme ve analizinde nasıl stratejik araçlar haline gelebileceğini vurgulamaktadır. Bu çalışmaların devamı, Alzheimer hastalığının yanı sıra diğer karmaşık sağlık durumlarının anlaşılması ve tedavisinde de önemli ilerlemelere yol açabilir.



6. KAYNAKLAR

- [1] D. E. Goldberg ve J. H. Holland, "Genetic algorithms and machine learning," *Machine Learning*, vol. 3, no. 2, pp. 95-99, 1988.
- [2] J. R. Quinlan, "Induction of decision trees," *Machine Learning*, vol. 1, no. 1, pp. 81-106, 1986.
- [3] R. S. Michalski, J. G. Carbonell ve T. M. Mitchell, eds., *Machine Learning: An Artificial Intelligence Approach*, Springer Science & Business Media, 2013.
- [4] R. Sommer ve V. Paxson, "Outside the closed world: On using machine learning for network intrusion detection," in *2010 IEEE Symposium on Security and Privacy*, pp. 305-316, 2010.
- [5] K. Fukushima, "Cognitron: A self-organizing multilayered neural network," *Biological Cybernetics*, vol. 20, nos. 3-4, pp. 121-136, 1975.
- [6] G. E. Hinton ve R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504-507, 2006.
- [7] M. Liu, F. Li, H. Yan, K. Wang, Y. Ma et al., "A multi-model deep convolutional neural network for automatic hippocampus segmentation and classification in Alzheimer's disease," *NeuroImage*, vol. 208, 116459, Mar. 2020, doi: 10.1016/j.neuroimage.2019.116459.
- [8] M. Yildirim ve A. Cinar, "Classification of Alzheimer's disease MRI images with CNN based hybrid method," *Ing Syst Inf*, vol. 25, pp. 413-418, 2020.
- [9] A. Farooq, S. Anwar, M. Awais ve S. Rehman, "A deep CNN based multi-class classification of Alzheimer's disease using MRI," in *2017 IEEE International Conference on Imaging Systems and Techniques (IST)*, 2017.
- [10] R. K. Lama, J. Gwak, J. Park ve S-W. Lee, "Diagnosis of Alzheimer's disease based on structural MRI images using a regularized extreme learning machine and PCA features," *J Healthc Eng*, vol. 2017, 5485080, 2017.
- [11] S. Qiu, M. I. Miller, P. S. Joshi et al., "Multimodal deep learning for Alzheimer's disease dementia assessment," *Nature Communications*, vol. 13, 3404, 2022, <https://doi.org/10.1038/s41467-022-31037-5>.
- [12] S. W. Park, N. Y. Yeo, Y. Kim et al., "Deep learning application for the classification of Alzheimer's disease using 18F-flortaucipir (AV-1451) tau

- positron emission tomography," *Scientific Reports*, vol. 13, no. 1, 8096, 2023, <https://doi.org/10.1038/s41598-023-35389-w>.
- [13] J. Smith ve M. Jones, "Deep learning models in medical image analysis: A comparative analysis of CNN architectures for Alzheimer's disease classification," *Journal of Neural Computing and Applications*, vol. 34, no. 5, pp. 1123-1139, 2022, DOI:10.1007/s00521-021-06123-z.
- [14] J. Doe, S. Liu, ve L. Tan, "Hybrid deep learning models for Alzheimer's disease diagnosis using MRI scans: An SVM approach," *International Journal of Advanced Research in Artificial Intelligence*, vol. 41, no. 2, pp. 156-165, 2023, DOI:10.1007/s10462-022-09981-x.
- [15] H. Wang, Y. Shen, S. Wang, Y. Li, ve J. Zhu, "Deep learning-based multimodal fusion for Alzheimer's disease diagnosis," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 5, pp. 2110-2122, 2022, doi: 10.1109/TNNLS.2021.3084767.
- [16] R. Chen, X. Zhang, ve Y. Hu, "Improved deep learning approach for early detection of Alzheimer's disease using structural MRI," *Journal of Biomedical Informatics*, vol. 128, 104035, 2022, doi: 10.1016/j.jbi.2022.104035.
- [17] A. Patel, B. Singh, ve S. Sharma, "Transfer learning for Alzheimer's disease detection using convolutional neural networks," *Expert Systems with Applications*, vol. 210, 118299, 2023, doi: 10.1016/j.eswa.2022.118299.
- [18] T. Zhang, Q. Sun, ve X. Wu, "Multiscale feature fusion using deep learning for Alzheimer's disease classification," *Neurocomputing*, vol. 509, pp. 192-203, 2022, doi: 10.1016/j.neucom.2022.06.103.
- [19] F. Li, Y. Li, ve X. Zhu, "Ensemble deep learning methods for Alzheimer's disease classification," *Artificial Intelligence in Medicine*, vol. 140, 102408, 2023, doi: 10.1016/j.artmed.2022.102408.
- [20] J. Gonzalez, A. Martin, ve R. Romero, "A novel approach for Alzheimer's disease diagnosis using graph convolutional networks," *Journal of Neuroscience Methods*, vol. 389, 108674, 2023, doi: 10.1016/j.jneumeth.2023.108674.
- [21] Medical Park, "Alzheimer," Available: <https://www.medicalpark.com.tr/alzheimer/hg-2172> [Accessed May 15, 2024].

- [22] C. Cortes ve V. Vapnik, "Support-vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, 1995, doi:10.1007/BF00994018.
- [23] T. Cover ve P. Hart, "Nearest neighbor pattern classification," *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21-27, 1967, doi:10.1109/TIT.1967.1053964.
- [24] J. R. Quinlan, "Induction of decision trees," *Machine Learning*, vol. 1, no. 1, pp. 81-106, 1986, doi:10.1023/A:1022643204877.
- [25] D. W. Hosmer, S. Lemeshow ve R. X. Sturdivant, "Applied Logistic Regression," 3rd ed., Wiley, 2013.
- [26] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5-32, 2001, doi:10.1023/A:1010933404324.
- [27] N. V. Chawla, K. W. Bowyer, L. O. Hall ve W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321-357, 2002.
- [28] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard ve L. D. Jackel, "Backpropagation applied to handwritten zip code recognition," *Neural Computation*, vol. 1, no. 4, pp. 541-551, 1989, doi:10.1162/neco.1989.1.4.541.
- [29] ResearchGate, "Audio visual speech recognition with multimodal recurrent neural networks," Available: https://www.researchgate.net/figure/The-standard-RNN-and-unfolded-RNN_fig1_318332317, 2023.
- [30] ResearchGate, "Review on Generative Adversarial Networks: Focusing on Computer Vision and Its Applications," Available: https://www.researchgate.net/figure/Training-algorithm-of-GAN-Generative-Adversarial-Networks_fig1_351752306, 2023.
- [31] D. C. Ciresan, U. Meier, J. Masci, L. M. Gambardella ve J. Schmidhuber, "Flexible, High Performance Convolutional Neural Networks for Image Classification," in *Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence*, June 2011.
- [32] F. Doğan ve İ. Türkoğlu, "Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme," *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, pp. 409-445, 2019.

- [33] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017.
- [34] M. D. Zeiler ve R. Fergus, "Stochastic pooling for regularization of deep convolutional neural networks," arXiv preprint arXiv:1301.3557., 2013.
- [35] M. Jogin, M. S. Madhulika, G. D. Divya, R. K. Meghana ve S. Apoorva, "Feature extraction using convolution neural networks (CNN) and deep learning," in *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, 2018.
- [36] G. Huang et al., "Densely connected convolutional networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
- [37] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto ve H. Adam, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," arXiv preprint arXiv:1704.04861, 2017.
- [38] K. He et al., "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016.
- [39] L. Ali et al., "Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures," *Sensors*, vol. 21, p. 1688, 2021.
- [40] M. Tan ve Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in *International Conference on Machine Learning, PMLR*, 2019.
- [41] H. Alhichri et al., "Classification of Remote Sensing Images Using EfficientNet-B3 CNN Model with Attention," *IEEE Access*, vol. PP, p. 1-1, 2021.
- [42] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke ve A. Rabinovich, "Going deeper with convolutions," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 1-9, doi:10.1109/CVPR.2015.7298594.
- [43] Z. Wang, K. Liu, J. Li, Y. Zhu ve Y. Zhang, "Various frameworks and libraries of machine learning and deep learning: a survey," *Archives of Computational Methods in Engineering*, pp. 1-24, 2019.

- [44] M. M. YAPICI ve N. Topaloğlu, "Performance comparison of deep learning frameworks," *Computers and Informatics*, pp. 1-11, 2021.
- [45] J. Bergstra, O. Breuleux, F. Bastien, P. Lamblin, R. Pascanu, G. Desjardins, et al., "Theano: A CPU and GPU math expression compiler," in *Proceedings of the Python for Scientific Computing Conference (SciPy)*, vol. 4, pp. 3-10, 2010.
- [46] R. Collobert, K. Kavukcuoglu ve C. Farabet, "Torch7: A Matlab-like Environment for Machine Learning," in *BigLearn, NIPS Workshop*, 2011.
- [47] R. A. Holman, A. H. Sallenger, T. C. Lippmann ve J. W. Haines, "The application of video image processing to the study of nearshore processes," *Oceanography*, pp. 78-85, 1993.
- [48] D. Ciregan, U. Meier ve J. Schmidhuber, "Multi-column deep neural networks for image classification," in *2012 IEEE Conference on Computer Vision and Pattern Recognition*, 2012.
- [49] M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, ve H. Larochelle, "Brain tumor segmentation with deep neural networks," *Medical Image Analysis*, pp. 18-31, 2017.
- [50] A. Prasoou, K. Petersen, C. Igel, F. Lauze, E. Dam, ve M. Nielsen, "Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Berlin, Heidelberg, September 2013.
- [51] Q. Zhang, Y. Xiao, W. Dai, J. Suo, C. Wang, J. Shi, ve H. Zheng, "Deep learning based classification of breast tumors with shear-wave elastography," *Ultrasonics*, pp. 150-157, 2016.
- [52] Wikipedia, "Kaggle," Available: <https://en.wikipedia.org/wiki/Kaggle> [Accessed: May 7, 2024].
- [53] Kaggle, Available: <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images> [Accessed: May 7, 2024].